

UNIVERSIDADE FEDERAL DO PARANÁ

CASSIUS TADEU SCARPIN

**UMA METODOLOGIA PARA A PREVISÃO DE DEMANDA DE PRODUTOS
UTILIZANDO REDES NEURAIS ARTIFICIAIS DE FUNÇÕES DE BASES RADIAIS
MODIFICADAS E UMA PROPOSTA DE LOGÍSTICA DE REPOSIÇÃO**

CURITIBA

2012

CASSIUS TADEU SCARPIN

**UMA METODOLOGIA PARA A PREVISÃO DE DEMANDA DE PRODUTOS
UTILIZANDO REDES NEURAIS ARTIFICIAIS DE FUNÇÕES DE BASES RADIAIS
MODIFICADAS E UMA PROPOSTA DE LOGÍSTICA DE REPOSIÇÃO**

Tese apresentada como requisito parcial à
obtenção de grau de Doutor em Ciências,
Programa de Pós-Graduação em Métodos
Numéricos em Engenharia, Setor de Ciências
Exatas e de Tecnologia, Universidade Federal do
Paraná.

Orientadora: Prof.^a Dr.^a Maria Teresinha Arns
Steiner

CURITIBA

2012

TERMO DE APROVAÇÃO

AGRADECIMENTOS

Agradeço a todos aqueles que de alguma forma contribuíram para que esse trabalho fosse desenvolvido. Quero agradecer a duas pessoas especiais: meu pai Renato Scarpin, que sempre esteve interessado em meu desenvolvimento, sendo sempre, além de pai, um amigo para todas as horas, o melhor amigo que uma pessoa possa ter, sincero e honesto; e minha esposa Dr^a Marianna Maia Taulois do Rosário, Nana, a qual sabe exatamente a dificuldade de realizar um trabalho desta magnitude e sempre esteve ao meu lado, mesmo nas horas de milhares de tarefas a serem cumpridas, ela me deu, da sua forma, seu apoio incondicional, ao qual só uma verdadeira amiga pode oferecer. Desta forma, tendo essas duas pessoas como meus alicerces, só me resta meu mais puro agradecimento

Preciso agradecer enormemente ao profissional Vladimir Torres Manriquez, um profissional do mais alto gabarito. Chileno-Brasileiro, o meu amigo Vladimir foi a pessoa que me abriu as portas para o tema e permitiu que pudéssemos vislumbrar o desenvolvimento de inovações, aplicações, gerando neste 4 anos inúmeros trabalhos, agregando muitos conhecimentos e criando um profissional cuja alcunha é forjada pelos alicerces mais nobres da vida mercadológica e supermercadista.

Devo agradecer também a toda equipe da empresa estudada, a qual sempre me recebeu muito bem e compartilhou inúmeras vezes de meus sonhos e desejos de conhecimento, em especial a profissional Raquel a qual se tornou uma amiga durante esses 4 anos. Ao Valderes, Paulo, Luiza, Giorgio e os demais da equipe, meus agradecimentos.

Gostaria de agradecer aos professores e colegas do PPGMNE, em especial ao Prof. Dr. Arinei, o qual me apoiou de verdade e o qual me espelho como exemplo de caráter, honestidade e retidão. Agradeço a nossa secretária Maristela por estar sempre disposta a nos atender com seu inigualável bom humor tradicional.

Por fim, meu agradecimento especial a minha orientadora Prof^a. Dr^a. Maria Teresinha, pois se alguém é responsável pelo meu crescimento pessoal e profissional é minha orientadora. Divido com ela todas as minhas conquistas, pois seu apoio, ajuda e compreensão tornaram-se imprescindíveis para chegar onde estou. Não há palavras para descrever minha gratidão, a ela agradeço do fundo do meu coração. Um dia, espero me tornar, pelo menos, parte da pessoa que ela é e isto já me tornaria um profissional de altíssimo gabarito.

“O mundo não é um grande arco-íris. É um lugar sujo, é um lugar cruel, que não quer saber o quanto você é durão, vai botar você de joelhos e você vai ficar de joelhos para sempre se você deixar. Você, eu, ninguém vai bater tão duro como a vida. ***Mas não se trata de bater duro, se trata de quanto você aguenta apanhar, e seguir em frente, o quanto você é capaz de aguentar e continuar tentando. É assim que se consegue vencer.*** Agora se você sabe o seu valor, então vá atrás do que merece. Mas tem que ter disposição para apanhar. E nada de apontar dedos e dizer que você não consegue por causa dele ou dela, ou de quem seja. Só covardes fazem isso e você não é covarde. Você é melhor do que isso”.

Rocky Balboa

RESUMO

Um dos principais problemas enfrentados no planejamento estratégico da cadeia de suprimentos de qualquer empresa é a previsão de demanda dos produtos e/ou serviços necessários. Obter informações da tendência do comportamento da demanda futura é imprescindível para a melhoria do nível de serviço em todos os setores de uma empresa. O problema abordado neste trabalho é a previsão de vendas de produtos aplicada a um sistema de reposição no varejo supermercadista. A programação de reposição de produtos pode ser otimizada de forma a maximizar a satisfação dos clientes (encontrando seus produtos nas lojas), minimizando a ruptura (falta de produtos nas gôndolas) dos mesmos e evitando a superestocagem. Estuda-se neste trabalho, de uma forma particular, o problema da ruptura que pode ocorrer na transição de produtos do Centro de Distribuição (CD) à Loja (CD-Loja). Utiliza-se, para isso, um método quantitativo clássico para a previsão de séries temporais, o algoritmo das Redes Neurais Artificiais de Função de Base Radial ou, simplesmente, Redes de Bases Radiais (RBF). Propõe-se neste trabalho, além de uma modificação no algoritmo das RBF, também um método qualitativo de interpretação dos resultados de previsão, com o estabelecimento de limites de estoque para cada produto de cada loja da rede. Analisou-se vários algoritmos de agrupamentos de padrões que podem ser utilizados na 2ª etapa do algoritmo das RBF e uma forma otimizada para se definir os seus parâmetros. Para melhor ilustrar a proposta, tomou-se por base dados reais de uma rede supermercadista, a qual utilizava o algoritmo das médias móveis para a previsão das séries temporais aplicado a um método de reposição baseada no tradicional método do ponto de pedido. Os resultados obtidos foram altamente satisfatórios reduzindo a ruptura CD-Loja, em média, de 12% para menos de 1% nos hipermercados e de 15% para cerca de 2% nos supermercados, gerando inúmeras vantagens competitivas para a empresa.

Palavras-chave: Reposição de Produtos. Redes Neurais Artificiais de Bases Radiais. Ruptura. Previsão de Séries Temporais. Nível de Serviço Logístico.

ABSTRACT

A major problem faced in the supply chain strategic planning of any company is the demand forecasting for products and / or services required. Information from the tendency of the behavior of future demand is essential to improve the service level in all company sectors. The problem addressed in this paper is sales forecasting of products applied to a replacement system in the retail supermarket. The schedule of replacement products can be optimized to maximize customer satisfaction (finding the products in the store), minimize the disruption (lack of products on the shelves) and avoid the super storage. It is studied in this paper, in a particular form, the disruption problem that may occur in the products transition from Distribution Center (DC) to Shop (DC-Store). It is used to this, a quantitative method for the classical time-series forecasting, the algorithm Neural Network Radial Basis Function or simply Radial Basis Networks (RBF). It is proposed in this work a change in the algorithm of RBF and also a qualitative method of interpreting the forecast results, with the establishment of limits of stock for each product at each store network. It was analyzed several algorithms for clusters of patterns that may be used in Step 2 of the RBF algorithm and an optimized way to define its parameters. To better illustrate the proposal, has become based on real data from a supermarket network, which uses the algorithm of moving averages to forecast time series applied to a reset method based on the traditional method from the point of application. The results were highly satisfactory reducing the break-CD Shop, on average, from 12% to less than 1% in hypermarkets and from 15% to about 2% in supermarkets, generating many competitive advantages for the company.

Key words: Product Replacement. Artificial Radial Basis Neural Networks. Out-of-Stock. Forecasting Time Series. Level of Logistics Services.

LISTA DE FIGURAS

FIGURA 2.1 – REPRESENTAÇÃO GRÁFICA DA POSSIBILIDADE DA RUPTURA.	30
FIGURA 2.2 – NÍVEIS DE RUPTURA - PESQUISAS BRASILEIRAS.....	38
FIGURA 2.3 – NÍVEIS DE RUPTURA - PESQUISAS COLOMBIANAS.....	39
FIGURA 2.4 – NÍVEIS DE RUPTURA – EMPRESA UNILEVER.....	40
FIGURA 2.5 – NÍVEIS DE RUPTURA – PESQUISAS MUNDIAIS.....	41
FIGURA 2.6 – CAUSAS DA RUPTURA NOS EUA	42
FIGURA 2.7 – CAUSAS DA RUPTURA - PESQUISAS BRASILEIRAS.....	43
FIGURA 2.8 – REAÇÕES DOS CLIENTES FRENTE A RUPTURA NOS SUPERMERCADOS	43
FIGURA 3.1 – ESQUEMA DE CLASSIFICAÇÃO DE TÉCNICAS DE PREVISÃO	47
FIGURA 3.2 – NEURÔNIO BIOLÓGICO: OS CONSTITUINTES DA CÉLULA	51
FIGURA 3.3 – NEURÔNIO ARTIFICIAL.....	52
FIGURA 3.4 – EXEMPLOS DE REDES <i>FEED-FORWARD</i>	55
FIGURA 3.5 – ESQUEMA DE UMA REDE RECORRENTE	55
FIGURA 3.6 – ARQUITETURA DAS REDES RBF	58
FIGURA 4.1 – REPRESENTAÇÃO ESQUEMÁTICA DA TÉCNICA <i>BOX PLOT</i>	70
FIGURA 4.2 – EXEMPLO DA REPRESENTAÇÃO GRÁFICA DA METODOLOGIA <i>BOX PLOT</i>	71
FIGURA 4.3 – DADOS ORIGINAIS PRODUTO PÊSSEGO 450G - 392 OCORRÊNCIAS	72
FIGURA 4.4 – EXEMPLO DE SUAVIZAÇÃO DOS DADOS	73
FIGURA 4.5 – FORMAÇÃO DAS MATRIZES PARA AS RBF	76
FIGURA 4.6 – DISTRIBUIÇÃO DOS ERROS NOS PRIMEIROS TESTES	81
FIGURA 4.7 – ERRO ACUMULADO NO TRATAMENTO DE DADOS	82
FIGURA 4.8 – ERRO ACUMULADO NA PORCENTAGEM DE PADRÕES PARA TESTE.....	83
FIGURA 4.9 – MÓDULO <i>RADBAS</i> DO MATLAB PARA O CÁLCULO DA FUNÇÃO DE ATIVAÇÃO.	85
FIGURA 4.10 – MÓDULO <i>CALCERRO</i> DO MATLAB PARA OBTENÇÃO DOS CENTRÓIDES	86
FIGURA 4.11 – MÓDULO <i>SOLVELIN</i> DO MATLAB PARA A OBTENÇÃO DOS PESOS	87
FIGURA 4.12 – ALGORITMO RBF	90
FIGURA 4.13 – PSEUDO-CÓDIGO DO ALGORITMO DAS <i>K</i> -MÉDIAS.....	92
FIGURA 4.14 – PSEUDO-CÓDIGO DO ALGORITMO DAS <i>K</i> -MÉDIAS MODIFICADO	93
FIGURA 4.15 – PSEUDO-CÓDIGO DO ALGORITMO DE TEITZ E BART (1968).....	94
FIGURA 5.1 – GRÁFICO COMPARATIVO: ERROS PELO NÚMERO DE CENTRÓIDES	103
FIGURA 5.2 – PROPOSTA PARA O ALGORITMO DAS <i>K</i> -MÉDIAS PARA A RBF	105
FIGURA 5.3 – QUANTIDADE DE CENTRÓIDES X ERROS MÉDIOS DE PREVISÃO	107
FIGURA 6.1 – ESQUEMA GERAL DA PROPOSTA PARA O SISTEMA DE REPOSIÇÃO	109
FIGURA 6.2 – COMPARAÇÃO DOS NÍVEIS DE ESTOQUE: ATUAL E PROPOSTA.....	116
FIGURA 6.3 – NÍVEIS DE RUPTURAS REAIS DO ESTUDO DE CASO	117

LISTA DE TABELAS

TABELA 4.1 – QUANTIDADE DE PRODUTOS POR DIVISÃO MERCADOLÓGICA E CLASSIFICAÇÃO ABC.....	79
TABELA 4.2 – RESULTADOS DOS PRIMEIROS TESTES REALIZADOS	80
TABELA 4.3 – ERROS OBTIDOS COMPARANDO OS TRATAMENTOS DE DADOS.....	81
TABELA 4.4 – ERROS OBTIDOS PARA PORCENTAGEM DE PADRÕES PARA TESTES.....	83
TABELA 4.5 – ERROS OBTIDOS PARA A DIMENSÃO DO PADRÃO DE ENTRADA.....	84
TABELA 4.6 – ERROS OBTIDOS PARA O FATOR <i>SPREAD</i>	84
TABELA 5.1 – TEMPOS COMPUTACIONAIS GASTOS NOS TESTES	95
TABELA 5.2 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS RMSE NO TREINAMENTO ...	97
TABELA 5.3 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS RMSE NO TESTE.....	98
TABELA 5.4 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS MAPE NA PREVISÃO.....	99
TABELA 5.5 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS MAPE NA PREVISÃO SEM OS PRODUTOS CLASSIFICADOS COMO CC	101
TABELA 5.6 – ERROS MÉDIOS DE PREVISÃO NOS TESTES PELO NÚMERO DE CENTRÓIDES	102
TABELA 5.7 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS MAPE NA PREVISÃO COM A APLICAÇÃO DA RBF PROPOSTA.....	106
TABELA 6.1 – PREVISÃO DE VENDA PARA DUAS SEMANAS	110
TABELA 6.2 – EXEMPLO DE CÁLCULO DOS VALORES DE ESTOQUE – ÁGUA SANITÁRIA.....	111
TABELA 6.3 – EXEMPLO COMPARATIVO DE SISTEMAS DE REPOSIÇÃO: REAL X SIMULADO.....	114

LISTA DE SIGLAS, SÍMBOLOS E ABREVIATURAS

ABRAS	- Associação Brasileira de Supermercado
AG	- Algoritmo Genético
ARIMA	- <i>Auto Regressive Integrated Moving Average</i> / Modelo Auto-Regressivo Integrado de Média Móvel
SA	- <i>Simulated Annealing</i>
BM&F	- Bolsa de Valores, Mercadorias e Futuros
CD	- Centro de Distribuição
CRM	- <i>Customer Relationship Management</i> / Gestão de Relacionamento com Clientes
DGP	- <i>Data Generation Process</i> / Processo Gerador do Dados
ECR	- <i>Efficient Consumer Response</i> / Resposta Eficiente ao Consumidor
EDI	- <i>Eletronic Data Interchange</i> / Troca de Informações por Meio Eletrônico
EM	- <i>Expectation Maximization</i>
FIR	- <i>Finite Impulse Response</i> / Resposta de Finitos Impulsos
GC	- Gerenciamento por Categorias
GCS	- Gerenciamento da Cadeia de Suprimentos
GRBF	- Redes Neurais Artificiais com Função de Crescimento de Base Radial
HPC	- <i>Home & Personal Care</i> / Divisão de Higiene e Beleza
HRDGA	- Ranking Hierárquico de Densidade do Algoritmo Genético
IA	- Inteligência Artificial
IBGE	- Instituto Brasileiro de Geografia e Estatística
ILP	- <i>Inductive Logic Programming</i> / Programação Lógica Indutiva
JIT	- <i>Just-in-Time</i>
LIFO	- <i>Last in First Out</i> / Último que Entra é o Primeiro que Sai
MATLAB	- <i>Matrix Laboratory</i> (Software para Cálculo Numérico)
MAPE	- <i>Mean Absolute Percentage Error</i> / Erro Médio Percentual Absoluto
MDL	- Modelos Dinâmicos Lineares
MEST	- Modelos Estruturais de Série de Tempo
MLP	- <i>Multilayer Perceptron</i>
MQO	- Método de Mínimos Quadrados Ordinários
MSE	- <i>Mean Relative Error</i> / Erro Relativo Médio
MRE	- <i>Mean Squared Error</i> / Erro Quadrático Médio
NMSE	- <i>Normalized Mean Square Error</i> / Erro Médio Quadrático Normalizado
OOS	- <i>Out-of-Stocks</i> / Ruptura
PDP	- <i>Parallel Distributed Processing</i> / Distribuição de Processamento Paralelo
PGBF	- Função Pseudo-Gaussiana de Base Radial
PIB	- Produto Interno Bruto
PO	- Pesquisa Operacional
RBF	- Redes Neurais Artificiais de Funções de Bases Radiais
RMSE	- <i>Root Mean Squared Error</i> / Raiz do Erro Quadrático Médio
RNA	- Redes Neurais Artificiais
RPROP	- <i>Resilient Backpropagation</i>
ROP	- Ponto de Pedido
SCM	- <i>Supply Chain Management</i>

SDL	- <i>Substitute, Delay and Leave</i> / Substituir o Item, Adiar a Compra ou Sair da Loja
SOM	- <i>Self Organizing Maps</i> / Maps Auto Organizáveis
SSE	- <i>Some of Squared Error</i> / Soma dos Erros Quadráticos
SVD	- Decomposição em Valores Singulares
SVR	- <i>Support Vector Machine Regression</i>
TI	- Tecnologia da Informação
TQM	- <i>Total Quality Management</i> / Gerenciamento da Qualidade Total
TS	- <i>Tabu Search</i>
UCM	- Modelo de Decomposição em Modelos Não Observáveis
VMI	- <i>Vendor Management Inventory</i> – Estoque gerido pelo fornecedor
WMS	- <i>Warehouse Management System</i> / Sistemas de Gerenciamento de Armazéns

SUMÁRIO

1 INTRODUÇÃO	13
1.1 OBJETIVOS DO TRABALHO	14
1.1.1 Objetivo Geral.....	14
1.1.2 Objetivos Específicos.....	14
1.2 IMPORTÂNCIA DO TRABALHO	15
1.3 LIMITAÇÕES DO TRABALHO.....	17
1.4 ESTRUTURA DO TRABALHO	17
2 DESCRIÇÃO GERAL DO PROBLEMA.....	19
2.1 O ESTUDO DE CASO ABORDADO.....	19
2.2 O GERENCIAMENTO LOGÍSTICO	23
2.2.1 Centros de Distribuição (CD)	26
2.2.2 Reposição de produtos nas lojas.....	28
2.2.3 Níveis de Rupturas	37
2.2.4 Causas da Ruptura.....	42
2.2.5 Decisões sobre políticas de estoques.....	44
2.2.6 O planejamento de estoques	44
3 TÉCNICAS PARA PREVISÃO DE VENDAS	46
3.1 TÉCNICAS ESTATÍSTICAS	48
3.2 REDES NEURAIS ARTIFICIAIS (RNA)	50
3.2.1 Neurônio Biológico e Artificial	50
3.2.2 Funções de Ativação	52
3.2.3 Topologia das RNA.....	54
3.2.4 Aprendizado das RNA	56
3.3 REDE NEURAL DE FUNÇÃO DE BASE RADIAL	56
3.3.1 Arquitetura das redes RBF	57
3.3.2 Processamento das RBF	58
3.3.3 Parâmetros e equações das redes RBF	59
3.3.4 Aprendizado em redes RBF.....	60
3.3.5 Estratégias de treinamento	64
3.3.6 Desempenho das redes RBF.....	65

4 PROPOSTAS PARA O TRATAMENTO DOS DADOS E DE MELHORIAS NAS RBF	67
4.1 PROPOSTAS PARA TRATAMENTO DOS DADOS	70
4.1.1 Primeiro tratamento	70
4.1.2 Segundo tratamento	72
4.2 DEFINIÇÃO DOS PARÂMETROS DA RBF	73
4.2.1 Parâmetro: Padrões de entrada.....	73
4.2.2 Parâmetro número de padrões para teste	75
4.2.3 Parâmetro: Fator dimensão dos campos receptivos.....	76
4.2.4 Testes e definições dos parâmetros	78
4.3 PROPOSTAS DE ALTERAÇÕES NAS RBF RELACIONADAS COM A ETAPA DE AGRUPAMENTOS DE PADRÕES	85
4.3.1 Algoritmos de agrupamentos e realização de alguns testes preliminares	88
5 TESTES E RESULTADOS COM AS RBF	95
5.1 DISCUSSÃO DOS RESULTADOS E PROPOSTAS DE MELHORIAS PARA A RBF	104
6 PROPOSTA PARA O SISTEMA DE REPOSIÇÃO E RESULTADOS ..	108
6.1 UTILIZAÇÃO DA PREVISÃO DE VENDAS	109
6.2 CÁLCULO DOS LIMITES	110
6.3 ESTRATÉGIA DE REPOSIÇÃO E EXEMPLOS NUMÉRICOS	112
7 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	118
REFERÊNCIAS.....	122
APÊNDICE	130

1 INTRODUÇÃO

A logística desempenha um papel fundamental no controle da disponibilidade de produtos nas lojas. Quando as pessoas realizam suas compras esperam encontrar todos os produtos de que necessitam disponíveis nas gôndolas da loja. Portanto, para garantir a satisfação e a confiança depositada pelo cliente no estabelecimento, cabe ao gerente, com o auxílio de um sistema de controle, prover e manter sempre disponíveis a maior variedade possível de produtos.

Quando se trata de uma rede de lojas, a oferta de produtos variados torna-se uma tarefa árdua para o gerenciamento, crescendo a necessidade de desenvolver sistemas de controles logísticos para a manutenção desse mercado de varejo. Em um mercado cada dia mais competitivo, um diferencial de uma rede varejista é a eficiência na disponibilidade de produtos em suas lojas.

Por esse motivo, a logística deve ser encarada como parte intrínseca do gerenciamento do sistema de estoque, desde a compra do produto de um fornecedor até a entrega do mesmo nas lojas ou diretamente para os clientes, quando for o caso. Esse é o princípio do gerenciamento da cadeia de suprimentos ou, também chamada, do *Supply Chain Management* (SCM). O gerenciamento logístico deve ser visto como uma ferramenta que necessita de melhoramentos periódicos e avanços tecnológicos constantes, procurando manter os estoques em níveis confiáveis, minimizando a falta de produtos ou a superestocagem dos mesmos.

Este trabalho foi desenvolvido com foco no sistema de reposição de estoques do Centro de Distribuição (CD) às lojas de uma rede de supermercados. Um dos objetivos em um CD é centralizar os produtos vindos de fornecedores e realizar a reposição dos mesmos nas lojas, minimizando custos operacionais e logísticos deste processo. O gerenciamento logístico de um CD de uma rede de varejo, por sua vez, tem como um de seus objetivos evitar a ruptura de produtos nas lojas, isto é, produtos não estarem disponíveis nas gôndolas dos estabelecimentos.

Na identificação das causas das rupturas, observa-se que um dos maiores motivos é a falha na reposição de produtos nas lojas. A programação de reposição deve acontecer de forma eficiente, mantendo um nível de estoque adequado para as vendas.

1.1 OBJETIVOS DO TRABALHO

O objetivo do trabalho é a melhoria do sistema de previsão de vendas para a reposição de produtos. Para isso, são apresentados o objetivo geral e os objetivos específicos a seguir.

1.1.1 Objetivo Geral

O histórico de vendas de cada produto forma uma série temporal de difícil previsibilidade e, assim sendo, tem-se como objetivo geral deste trabalho, apresentar uma ferramenta matemática computacional que faça a previsão de vendas, com base nas séries temporais, e que utilize essas informações para o planejamento operacional da reposição desses produtos.

São aqui propostas melhorias para o algoritmo de Redes Neurais Artificiais de Bases Radiais (RBF) para previsão de Séries Temporais e, fazendo uso destes resultados, apresenta-se uma proposta para um novo sistema de reposição de estoques, com parâmetros flutuantes de estoque mínimo, ponto de pedido (estoque limite), estoque máximo e quantidade ótima de reposição. Com este procedimento, espera-se atender satisfatoriamente a demanda dos clientes, assim como minimizar a ruptura e a superestocagem de produtos. A proposta é ilustrada com a aplicação a um problema real de previsão de vendas de produtos de uma rede varejista supermercadista.

1.1.2 Objetivos Específicos

Os objetivos específicos podem ser listados da seguinte forma:

- Estudar as séries temporais geradas pelas vendas dos produtos.
- Revisar os principais métodos de previsão de séries temporais baseados em RNA encontrados na literatura.

- Encontrar uma configuração mais adequada para aplicar em todos os produtos, sem ter a necessidade de treinar as RBF com diversos tipos de configurações.
- Definir os níveis de estoque para a reposição de produtos.
- Propor um novo processo de reposição baseado nas previsões de vendas.
- Medir a ruptura dos produtos, com a metodologia completa implementada e analisar os resultados

1.2 IMPORTÂNCIA DO TRABALHO

A acirrada concorrência entre empresas tem feito com que as mesmas procurem melhorar o seu nível de serviço e o atendimento a seus clientes, além de aprimorar a eficiência de resposta às necessidades reais de mercado. Para que todas essas premissas sejam atendidas, as empresas necessitam desenvolver metodologias e processos gerenciais mais completos, que contemplem mais variáveis, gerando respostas mais rápidas aos clientes. O dinamismo é fator que mais caracteriza o mercado varejista, pois busca operações mais econômicas, organizadas e enxutas visando aumentar a produtividade dos funcionários para atender com rapidez a necessidade do cliente.

A dinâmica do mercado varejista e os conceitos de gestão eficiente são fatores que forçam os níveis de estoques das lojas estarem cada vez mais baixos, porém, sem correr os riscos de faltar os produtos nas gôndolas, gerando a ruptura. Em uma rede de mercados varejista, que possui um CD, as operações logísticas podem causar impactos efetivos nos processos, sendo responsável por manter a rede de lojas abastecida e com níveis de estoque não excedentes. Através de técnicas da área de Pesquisa Operacional pode-se quantificar e aperfeiçoar os processos do CD de modo a diminuir os custos operacionais, dando agilidade aos processos e aumentando a produtividade da empresa. Assim, busca-se responder suas demandas, procurando se adaptar o mais rápido possível às variações do mercado.

No CD são organizadas e realizadas operações de recebimento, estocagem, abastecimento e distribuição dos produtos. Para cada uma dessas operações existem metodologias que podem e devem ser melhoradas e otimizadas frequentemente. Para que isso possa ocorrer, percebeu-se a necessidade de possuir informações futuras do comportamento de compra dos clientes, isto é, possuir uma previsão de vendas confiável o suficiente para se antecipar nas ações de reposição de produtos nas lojas, buscando uma resposta efetiva para a diminuição do nível de rupturas das lojas de uma rede varejista.

A cada dia, a variedade de produtos no mercado é mais diversificada, exigindo um tempo de resposta cada vez mais curto e entregas cada vez mais freqüentes. Portanto, é inviável para um CD organizar todos seus processos manualmente, tornando-se necessário o desenvolvimento de ferramentas computacionais da tecnologia da informação. No mercado existem muitos programas para o auxílio do gerenciamento de um CD.

Estes sistemas são desenvolvidos por empresas especializadas ou pela equipe de tecnologia de informações (TI) da própria rede varejista, cujo objetivo é solucionar problemas gerenciais gerais, como: controle de estoque, controle de notas fiscais, localização de produtos dentro do CD, controle de recebimento e expedição de produtos, entre outras. O sistema mais conhecidos para o controle de estoque é o chamado *WMS (Warehouse Management System* ou Sistemas de Gerenciamento de Armazéns). Alguns destes sistemas são capazes de fazer a previsão de vendas ou de demanda de maneira simplificada, porém, apesar de gerenciar muitas operações, estes *softwares* não são capazes de contemplar a totalidade das atividades realizadas dentro de um CD.

O estudo dos processos logísticos dentro do CD e o melhoramento de previsão de vendas, quando usados em conjunto, fazendo uso de sistemas computacionais, pode formar uma metodologia com maior eficácia de gerenciamento e gestão de estoques. Isto contribuirá na eficiência e qualidade dos serviços prestados aos clientes. A melhoria de qualidade de atendimento se dá uma vez que, diminuindo os índices de ruptura das lojas, os clientes ficarão cada vez mais satisfeitos com a variedade, qualidade e oferta (ou seja, não havendo a falta) dos produtos oferecidos fazendo com que o lucro das empresas aumente, além da imagem da rede varejista ficar fortalecida.

1.3 LIMITAÇÕES DO TRABALHO

Existem inúmeras operações realizadas dentro de um CD, assim como existem inúmeros processos a serem gerenciados em uma rede varejista. Este trabalho limita-se ao estudo de previsão de demanda dos produtos nas lojas e o sistema de reposição dos produtos entre o CD e as lojas.

Para isso, foi realizado o estudo e a melhoria do algoritmo RBF aplicado a previsão de séries temporais com poucas ocorrências, devido a característica do problema abordado e ao modelo proposto, procurando priorizar a qualidade e acurácia dos resultados e deixando em segundo plano o tempo computacional gasto. Nada impede a aplicação da ferramenta aqui desenvolvida em séries temporais com grande quantidade de ocorrências, porém, não é este o foco abordado, sendo esta uma limitação do trabalho.

1.4 ESTRUTURA DO TRABALHO

O trabalho está assim dividido: No capítulo 2 faz-se a descrição geral do problema abordado. Discutem-se as variáveis necessárias para o desenvolvimento das soluções e são delimitados os problemas abordados neste trabalho referentes ao gerenciamento logístico de um CD. Neste capítulo é feito, também, uma discussão sobre a ruptura de produtos, suas implicações e características. Além de tratar sobre o assunto de políticas de estoques e sistemas de reposição de produtos.

As técnicas de previsão de séries temporais são abordadas no capítulo 3. Também, neste capítulo, encontra-se a metodologia básica das RNA, bem como a descrição do algoritmo de RBF e seus parâmetros. No capítulo 4 aborda-se as propostas para obtenção dos parâmetros da RBF referente a metodologia estudada, a implementação e as melhorias realizadas nas RBF. Neste capítulo é que se apresenta os procedimentos utilizados para definição da arquitetura da RBF e a forma com que foram implementadas as metodologias estudadas.

O capítulo 5 contém os resultados obtidos e as propostas de melhorias da RBF e no capítulo 6 as propostas para o sistema de reposição com parâmetros

flutuantes. No capítulo 7 são apresentadas as conclusões do trabalho, comentando os resultados obtidos e fazendo sugestões para continuidade da pesquisa. No apêndice apresenta-se um levantamento bibliográfico dos trabalhos com assuntos correlatos aos tratados neste trabalho, o qual serviu como baliza para o desenvolvimento deste.

2 DESCRIÇÃO GERAL DO PROBLEMA

Foi analisada uma rede supermercadista para melhor amparar a proposta de planejamento estratégico para a reposição de produtos em lojas aqui apresentada. A empresa conta com uma frota própria para realizar as entregas diárias dos pedidos das lojas e todo controle de estoque, separação e expedição é feita pela própria empresa.

Para o controle de todas as informações, a empresa estudada desenvolveu um sistema próprio de gerenciamento, através de sua equipe de tecnologia da informação. Neste sistema estão contemplados, dentre outros módulos, os seguintes sistemas: de previsão de vendas; de reposição automática de produtos; de separação dos produtos no CD; de roteamento de entregas; entre muitos outros módulos gerenciais e administrativos. Neste trabalho pretende-se otimizar o sistema de reposição automática de produtos, utilizando uma estratégia de previsão de vendas mais confiável e aplicando seus resultados na elaboração automática dos pedidos diários das lojas.

O índice de ruptura aqui mensurado é considerado a partir do momento que um produto fica com estoque zerado na loja, com disponibilidade no CD. Como as modernas técnicas de gestão comercial privilegiam o baixo estoque, os empresários devem ajustar, ao máximo, o nível de seus produtos e serviços às necessidades dos clientes. É preciso ter em mente que, quando as pessoas vão às lojas, elas compram além do planejado, podendo o comércio lucrar bastante com o estímulo às compras por impulso. Por maior que seja o esforço do comerciante, de nada valerão as ações se não houver a disponibilidade de produtos nas gôndolas (prateleiras) das lojas.

2.1 O ESTUDO DE CASO ABORDADO

O setor supermercadista, um dos mais importantes do varejo, vem passando por grandes transformações. Alguns fatos históricos na economia brasileira, como a entrada em vigor do Código de Proteção e Defesa do Consumidor, implantação do

plano real e o controle do índice de inflação, aumentaram, ainda mais, a competitividade entre as empresas desse setor.

Com este cenário competitivo, torna-se essencial para uma empresa traçar estratégias efetivas e bem definidas para atingir o objetivo de oferecer ao consumidor preços atraentes, grande sortimento ou *mix* de produtos e qualidade nos serviços prestados. Nesse ambiente, em que a competição obriga a realização da atividade com margens reduzidas, é fundamental que as empresas comerciais atentem para as condições operacionais (ÂNGELO; SIQUEIRA, 2000).

O setor supermercadista representa 5,5% do PIB nacional e oferece cerca de 788 mil empregos diretos, segundo os dados publicados na Revista Super Hiper (2005). Já os dados divulgados em 2008, pela mesma revista, mostram que os supermercados representam 22,8% dos empregos do varejo e pagam salários até 20% superior do que a média do varejo.

Os faturamentos combinados das 20 maiores redes supermercadistas do Brasil cresceram 20,1% em 2010, na comparação com o ano anterior, somando R\$ 115,8 bilhões, de acordo com o 34º Ranking Abras, elaborado pela Associação Brasileira de Supermercados (Abras), em parceria com a Nielsen, empresa de pesquisa de mercado. No total, o faturamento do setor somou R\$ 200,1 bilhões, o que significa um crescimento de 13,9% ante 2009, em valores nominais¹.

O seu desenvolvimento possibilita a manutenção destes empregos e a ampliação das vagas. A Pesquisa Anual do Comércio de 2005 divulgada pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2007) analisa as vendas de supermercados e hipermercados e mostra que a participação destes nas vendas do comércio varejista em 2005 representou 24% do total. Estas informações revelam, devido a sua grandeza em valores, a contínua necessidade das empresas em aprimorar os métodos de gestão e planejamentos estratégicos para conquista e manutenção de seu mercado consumidor.

Conseqüentemente, tem-se aumentada a necessidade de obter maior desenvolvimento de ferramentas que auxiliem a tomada de decisão, as quais podem contribuir para um aumento dos níveis de serviços oferecidos pelas empresas varejistas. Um setor destas empresas que pode absorver os novos métodos e

¹ Informação divulgada pela equipe AgriPoint e postada em 31/03/2011. Acessado em 05/07/2011. <<http://www.cafepoint.com.br/cadeia-produtiva/giro-de-noticias/setor-supermercadista-aumenta-faturamento-em-2010-70731n.aspx>>

ferramentas é o setor operacional, pois a excelência em atendimento aos clientes está diretamente relacionada com a qualidade das operações realizadas, tanto internamente, como diretamente ao cliente.

Com a finalidade de ilustrar as propostas apresentadas neste trabalho, fez-se a aplicação das mesmas a uma empresa paranaense do setor supermercadista e, por esse motivo, a mesma é brevemente descrita aqui.

A empresa possui uma rede com 34 lojas distribuídas no estado do Paraná, sendo 16 na capital, Curitiba, 9 na região metropolitana de Curitiba e as demais 9 pelo interior do estado, e estava posicionada, em 2009, como a 12ª maior rede supermercadista do Brasil, segundo o Ranking da ABRAS – Associação Brasileira de Supermercados. Em 2011 alcançou a 8ª posição deste mesmo *ranking*, considerando o faturamento apenas no modelo de negócios supermercado\hipermercado².

Possui um CD, com aproximadamente: 50.000 m² de área útil, estacionamento com 7.500 m², 40.000 endereços de estoque, sendo 10.000 endereços de área de *picking*, 30.000 produtos, sendo que destes, 60% são centralizados, isto é, entregues no CD pelos fornecedores, sendo parte desses centralizados alvo de estudo neste trabalho. Nestas lojas são comercializados cerca de 23.000 produtos, dos quais cerca de 10.500 são produtos centralizados (os fornecedores entregam os produtos aos CDs da rede) e 12.500 são entregues diretamente pelos fornecedores às lojas.

O nível de ruptura das lojas, por ocasião da pesquisa, girava em média entre 10% e 12% e atingia picos de 15%, considerando os produtos objetos de estudo. Os produtos centralizados estudados, cerca de 8000 itens diferentes, são responsáveis por mais de 80% do giro financeiro da empresa. Este nível de ruptura gera uma perda de lucratividade de difícil mensuração, pois não existe modo de se medir a insatisfação dos clientes ou quantos clientes deixaram de comprar algum produto.

Dentre os produtos centralizados, cerca de 8.000 produtos são classificados como de “área seca”. Dentro desta área está o setor de Mercearia, que engloba os produtos das famílias de Alimentos; Higiene e Beleza; Limpeza; Bebidas e Importados, e os setores de Eletro, Pet Shop e Bazar. Os outros 2.500 produtos são da área de resfriados/congelados como, por exemplo, produtos das famílias: Frios;

² <<http://www.condor.com.br/content/conteudo/conteudo.view.php?id=385>> Acesso em 05/07/2011

Margarinas; Carnes; Congelados e Perecíveis. Neste trabalho a metodologia foi aplicada aos produtos da “área seca”.

Com base na literatura e estudo de mercado, percebeu-se a necessidade de desenvolvimento de uma ferramenta computacional que pudesse prever a demanda de cada produto para que as operações logísticas pudessem ser antecipadas obtendo, assim, a melhoria do nível de serviço ao cliente e, claro, evitar a ruptura, gerando assim o interesse de desenvolvimento desta pesquisa.

A base de toda operação logística é a distribuição de produtos as lojas, e, por isso, saber a quantidade de cada produto que será levado a cada loja, a cada dia, sem deixar a loja com superestocagem ou sem causar a ruptura dos mesmos, é o principal desafio da gestão dos estoques da rede. Para se conhecer este valor necessita-se de um método de previsão que possa direcionar as ações para o comportamento futuro de compra dos clientes.

O sistema de reposição encontrado na empresa estudada era baseado nas médias móveis e nos pedidos dos gerentes das lojas, que se mostrou ineficiente para uma generalização da reposição para todos os produtos. A estratégia de reposição automática era calculada com base nas médias móveis dos últimos 30 dias e quando o estoque ficava menor do que a média, então era sugerida a reposição do produto em uma quantidade pré-estabelecida, determinada pelo gerente da loja e ajustada conforme necessidade encontrada por esse mesmo gerente.

Um problema encontrado constantemente com a aplicação desta técnica é o fato de que, por motivos diversos, a venda seja muito maior do que a tendência natural, fazendo com o valor das médias fosse alterado e o estoque se tornasse muito grande, causando a superestocagem. De modo análogo, se em um ou mais dias seguidos, a venda é muito menor do que o normal (devido a chuvas ou outro fator externo qualquer), o valor médio de venda sofreria uma distorção para baixo, aumentando a probabilidade de ruptura. Qualquer um dos fatos citados é agravado principalmente se coincidir com a chegada do fim de semana, pois não há reposição de produtos do CD para as lojas aos domingos.

As operações de reposição no CD (separação de produtos, carregamento dos caminhões e expedição) aconteciam em maiores quantidade nas segundas-feiras, quando eram repostos os produtos vendidos durante os finais de semana. A média de caixas separadas e carregadas nas segundas-feiras era superior a 55.000,

enquanto que nas quartas-feiras e quintas-feiras, a média girava em torno de 13.000. Isso significava um pico de atendimento e de operações logísticas no início de cada semana, gerando um gargalo operacional no CD.

São trazidos a tona, na seção 2.2 seguinte, temas relacionados com o gerenciamento logístico de um CD, já que o problema aqui abordado está enquadrado em seu contexto. Os problemas gerenciais apresentados, embora discutidos de forma superficial e individualmente, estão interligados ao gerenciamento logístico do CD.

2.2 O GERENCIAMENTO LOGÍSTICO

Gerenciar um CD não é uma tarefa fácil nos dias atuais. Se por um lado têm-se tecnologias avançadas para realizar o controle de produtos, como leitores de código de barras e sensores por ondas de rádio, por outro lado têm-se custos altíssimos que devem ser evitados, quando possível. Quando os processos são realizados extraindo o máximo de sua produtividade e a tarefa a ser realizada ainda não está satisfazendo as expectativas, o gestor pode procurar processos alternativos, otimizando operações, ou adquirir novas tecnologias para suprir suas necessidades.

Possuir um sistema gerencial que seja capaz de controlar e utilizar o máximo das operações é um dos objetivos de todas as empresas. Estas procuram reduzir custos operacionais sempre que possível, investindo em equipamentos caros somente em último caso. O planejamento de investimentos em novas tecnologias também é uma constante nas empresas, porém se for possível suprir um aumento de demanda, em certa operação, com uma mudança de processo, a empresa economizará e poderá trabalhar de modo mais enxuto.

Basicamente, o gerenciamento logístico está atrelado à origem e ao destino dos produtos. Seja vindo dos fornecedores para o CD, seja na movimentação interna destes no CD ou, ainda, seja na distribuição para as lojas e/ou clientes. Os produtos que estão a vendas nas lojas podem ali chegar basicamente de duas maneiras:

a) direto nas lojas: o fornecedor entrega os produtos diretamente para as lojas, fazendo a chamada entrega loja-a-loja, e/ou com caminhões das lojas que vão buscar os produtos diretos nas fábricas dos fornecedores ou;

b) via entrega centralizada: onde os fornecedores entregam seus produtos no CD da rede de lojas ou em um CD terceirizado que, por sua vez, realizam as entregas dos produtos para as lojas conforme a necessidade de reposição.

Neste trabalho, o foco fica restrito somente a “entrega centralizada”. O modelo de Gestão de Estoques pode ser realizado de várias formas, entre as mais conhecidas e utilizadas estão: O controle de estoque realizado pela própria empresa; o *Vendor Management Inventory (VMI)*, onde o estoque é gerido pelo fornecedor da empresa, podendo entregar para as lojas ou para o CD, de acordo com a necessidade do cliente e a decisão do fornecedor; ou então, uma forma mais recente utilizada no país que são as Lojas *in-Company*, a qual se resume a situação do fornecedor instalar uma loja internamente na empresa cliente.

Citam-se, a seguir, algumas das etapas mais importantes de toda a cadeia logística, de forma a auxiliar em um melhor entendimento do problema principal aqui abordado. As etapas foram determinadas de acordo com a sua relevância para o objetivo final de uma empresa: oferecer o melhor nível possível de serviço ao cliente. As etapas foram definidas como sendo:

1. Sugestão de compras juntos aos fornecedores de produtos centralizados;
2. A localização de produtos dentro do CD, especificamente na área de *picking*;
3. O trânsito interno de pessoas e maquinários nas operações de armazenamento, ressuprimento e separação de produtos;
4. A separação de produtos e o carregamento dos caminhões;
5. A reposição de produtos nas lojas;
6. As entregas centralizadas diretas para os clientes.

Uma rede varejista necessita programar suas compras de produtos junto a seus fornecedores. Nesta programação deve considerar seu nível de estoque, que deve ser suficiente para certo período, a capacidade de produção do fornecedor, o tempo de entrega do fornecedor, o tempo de vencimento do produto, se houver, entre outros aspectos. Neste contexto surge, então, a necessidade de prever a demanda de venda para auxiliar no cálculo da quantidade de produtos nos pedidos de compra.

Quando um produto é entregue no CD, ele deve ser recebido e armazenado, e também, deve ser separado e expedido para as lojas, conforme a reposição programada desse produto. Para cada uma dessas operações básicas existem processos envolvidos que podem ser melhorados. Um problema básico de todo CD é a localização onde este produto será armazenado: seja na área de *picking* (endereços de armazenamento geralmente na altura no chão), seja no armazenamento aéreo (endereços dos níveis logo acima dos endereços de *picking*). A classificação de produtos para armazenagem é outro problema gerenciado no CD, pois os produtos podem ser classificados por categorias mercadológicas, curvas ABC de vendas, similaridade de características, entre tantas outras existentes. Para este problema ainda há peculiaridades que devem ser consideradas, como produtos de alto valor agregado, produtos com algum tipo de cuidado especial e ainda alguma característica específica da rede varejista.

Quando se determina que o produto deva ser separado para reposição, a realização das operações para tal finalidade deverá ser conciliada com as operações de armazenamento e ressuprimento. As operações ocorrem simultaneamente podendo ocasionar tráfego intenso nas “ruas” internas do CD e, este fato, deve ser contemplado na programação de atividades diárias realizadas. Para que seja feito o controle e gerenciamento desses processos necessita-se do conhecimento total de todo o maquinário e pessoal disponível para a realização dessas tarefas. Além disso, precisa-se de processos que contemplem a total utilização dos recursos disponíveis, minimizando gargalos operacionais dentro do CD.

Com isso, o gerente logístico deve saber quando o produto deve ser carregado nos veículos para a entrega de reposição nas lojas, quanto de cada produto deve ser entregue e como realizar essa separação e carregamento. A quantidade de cada produto separado para reposição deve ser calculada prevendo a cobertura de estoque de certa quantidade de dias, porém sem causar a superestocagem. O pedido de reposição feito diariamente pelas lojas, automático ou manual, para o CD, deve possuir uma relação de produtos com quantidades suficientes para manter a disponibilidade do *mix* na loja ao máximo e não ocasionar a ruptura.

Ao mesmo tempo, se a rede varejista decide realizar entregas centralizadas para clientes, isto é, além de atender aos pedidos nas lojas, realizar as entregas feitas com estoque do CD, o gerente necessitará de, além da separação do pedido,

um roteiro para o caminhão de entregas. Caso a quantidade de produtos que necessite ser entregue ocupe mais que um caminhão, então surgirá a necessidade de um sistema de designação de entregas por caminhão, regionalização de entregas e roteamento dos veículos.

Todas essas operações mencionadas fazem parte do gerenciamento logístico do CD e devem, sempre que possível, serem planejadas de forma a realizá-las com os menores custos possíveis, otimizando-se esses processos.

2.2.1 Centros de Distribuição (CD)

A distribuição de produtos passou a procurar operações mais eficientes devido a concorrência existente no mercado atual. A filosofia operacional *Just-in-Time* estabelece que as respostas dadas aos clientes devam ser cada vez mais rápidas e o tempo entre o pedido e a entrega reduzido ao máximo. Essa filosofia busca a qualidade dos serviços prestados, através da melhoria da produtividade e o aumento da importância da funcionalidade e capacidade dos sistemas de controle de armazéns e manuseio de materiais.

Os armazéns ou CDs possuem a missão de conter estoques usados para equilibrar e amortecer a variação entre as programações de produção e a demanda. Pode também ter como missão, acumular e consolidar produtos de diferentes pontos de fabricação dentro da mesma empresa, ou de várias empresas, para a remessa combinada a clientes comuns. Se uma empresa varejista, que possui várias lojas filiais, decide trabalhar com um CD, então as missões citadas se confundem e se tornam uma única missão para a rede: armazenar e repor produtos para as lojas de modo a não causar ruptura, nem tampouco a superestocagem, considerando sempre a filosofia de estocagem da empresa.

Embora intuitivamente possamos imaginar que o CD sirva apenas para estocar produtos, várias atividades, processos e operações estão atrelados às movimentações de produtos para dentro do CD, internamente ao CD e para fora do CD. Definem-se operações como sendo as ações parciais dentro de um processo geral ou uma atividade.

Exemplificando para a atividade de recebimento de produtos, isto é, do momento da chegada do caminhão do fornecedor até a estocagem propriamente dita no espaço reservado daquele produto. A atividade é o recebimento, os processos podem ser divididos em duas partes, burocráticos e operacionais, sendo que em cada processo realizam-se as operações referentes a estes, como entrada da nota, lançamento da nota fiscal no sistema, lançamento do produto no estoque, definição do endereço do produto, entre outras operações. Isto significa que a atividade (tarefas ou funções) de recebimento é comum em todos os CDs e sempre terá que acontecer. O processo que a empresa, através do gerente logístico, adota para realizar estas tarefas, pode mudar, pois existem inúmeras maneiras de realizá-las. E ainda, dentro de um processo definido podem existir operações específicas que podem ser alteradas sem a mudança do processo como um todo.

As atividades de um CD são basicamente quatro: Recebimento, Estocagem, Separação e Expedição. Outras atividades também são realizadas, como: pré-embalagem, *packing* e *cross-docking*. Estas atividades serão encaradas como parte das quatro atividades básicas.

Para que se tenha um gerenciamento efetivo do CD, o gerente logístico precisa estabelecer bem os processos realizados para cada uma das atividades, determinando quais, quando e como as operações devem ser realizadas, considerando o maquinário disponível (paleteiras, transpaleteiras, empilhadeiras, etc.), a equipe de operação, e as atividades que estão sendo executadas ao mesmo tempo. Cabe aqui ressaltar a importância da previsão de vendas e a consequência de se obter uma antecipação da organização das atividades, dado que se tenha uma boa previsão.

A utilização de *softwares* comerciais para o auxílio da gestão do CD é uma prática comum e, muitas vezes, indispensável, pois a quantidade de informações, operações e controles que se deve ter, torna o gerenciamento inviável manualmente. O sistema *WMS* é um conjunto de programas de computador desenvolvidos para automatizar o fluxo de produtos por todo armazém, controlando, a princípio, todo movimento de estoques dentro do CD.

Entretanto, um sistema de *WMS*, por mais completo e complexo que seja, está restrito ao controle de estoque dentro das operações. Esse sistema gerencia as informações do CD em relação aos produtos, como: quantidade, localização, volume, tipo de embalagem, necessidade de ressurgimento de *picking* e outras

informações sobre os produtos; as necessidades de um CD, porém, vão além desses controles. O gerente logístico precisa definir como os funcionários vão separar os produtos na área de *picking* para o carregamento de um caminhão, qual é a melhor localização dos produtos para “agilizar” o processo, quanto de cada produto é necessário separar para não ocorrer riscos de ruptura nas lojas, entre outras decisões operacionais.

Enfim, o CD de uma rede varejista possui uma missão muito maior do que simplesmente armazenar produtos, deve realizar as operações de modo rápido, preciso e com o menor custo possível. Por este motivo, muitas empresas, ao invés de adquirir *softwares* de WMS, estão criando suas próprias equipes de Tecnologia da Informação (TI) para o desenvolvimento de seus sistemas.

Assim, além de possuir um sistema próprio, a equipe de TI pode personalizar ou “customizar” seu gerenciamento com as particularidades da rede varejista, incluindo módulos operacionais que facilitam as tarefas diárias do CD. Neste trabalho, em decorrência do sistema de reposição proposto, pretende-se inovar sobre a visão do gerenciamento do CD, discutindo a importância de, além de controlar com eficiência o estoque, realizar as operações como um processo de produção único, onde a decisão sobre uma operação influencia sobre outra operação.

2.2.2 Reposição de produtos nas lojas

Como as modernas técnicas de gestão comercial privilegiam o baixo estoque, os empresários devem ajustar, ao máximo, os produtos e serviços às necessidades dos clientes. É preciso ter em mente que, quando as pessoas vão às lojas, elas compram além do planejado, podendo o comércio lucrar bastante com o estímulo às compras por impulso. Por maior que seja o esforço do comerciante, de nada valerão as ações se não houver disponibilidade de produtos nas gôndolas (prateleiras) das lojas. Cabe ao CD viabilizar de forma competitiva o fluxo de mercadorias vindas dos fabricantes, até os seus diversos graus de capilaridade distributiva.

A ruptura causa perdas maiores do que simplesmente a não-venda do produto faltante, pois pode causar a insatisfação do cliente que, por sua vez, pode acarretar a diminuição no volume da sua compra; o abandono do carrinho de compras e ir embora e/ou nunca mais voltar a comprar nessa loja. Nas empresas de varejo supermercadistas, o setor mais importante das lojas é a mercearia, no qual, em média, 80% dos produtos estão classificados. O índice de ruptura é mensurado sempre que um produto fica com estoque zerado na loja, sendo que suas causas podem ter motivos diversos, entre os quais estão: os produtos não foram programados para a reposição ou a reposição foi insuficiente.

O problema principal é a sugestão automática de reposição de produtos. Gerar uma lista de produtos que devem abastecer a loja para que não ocorra a ruptura, e também, preocupar-se com um limite de estoque máximo de cada produto, para que não gere a superestocagem são os fatores-chaves da reposição. Há na literatura muitos trabalhos, métodos e sugestões sobre a estratégia de reposição. De uma forma geral, os métodos podem ser qualitativos, onde se preocupa com os dados descritivos e exploratórios sobre pessoas, lugares e processos interativos, ou quantitativos, que focam na medição objetiva e na quantificação de produtos que devem estar disponíveis nas gôndolas das lojas.

2.2.2.1 O sistema de reposição

De uma forma geral, tem-se que para a reposição de produtos, deve-se obter uma previsão de demanda, um ponto de reposição, um tamanho do lote do pedido e uma forma de atualizar estas informações. Este se chama de modelo de controle do ponto de pedido. Alternativamente a este, pode-se realizar a reposição através de um modelo de revisão periódica, no qual os níveis de estoques para múltiplos itens podem ser revisados ao mesmo tempo para serem encomendados ao mesmo tempo (BALLOU, 2006). Nas políticas de revisão periódica, os níveis de estoque são revisados após um período fixo e um pedido é feito de modo que o nível de estoque atual mais o tamanho do lote de reposição seja igual a um nível previamente especificado, chamado de nível máximo de pedido (CHOPRA e MEINDL, 2010).

Em todas essas variantes, a incerteza da demanda e da previsão pode ocasionar a falta de produtos, a ruptura, independente da complexidade da fórmula utilizada para cálculo do ponto de pedido, quantidade do pedido, prazo para a reposição (*lead-time*) e intervalo entre os pedidos. Na Figura 2.1 apresenta-se, de uma forma simplificada, um exemplo do problema de incerteza dos cálculos e o surgimento da ruptura.




FIGURA 2.1 – REPRESENTAÇÃO GRÁFICA DA POSSIBILIDADE DA RUPTURA.
FONTE: O AUTOR (2011).

Neste exemplo tem-se que a previsão de venda é de 3 unidades por dia, o ponto de reposição será quando o estoque ao final do dia estiver menor ou igual a 3, o lote de compra é de 9 unidades ou múltiplos de 9, e o prazo de entrega é de um dia, isto é, o pedido feito em um dia, será entregue no final do dia seguinte. Os pedidos foram feitos nos dias 4, 9 e 15, mas têm-se situações diferentes em cada um deles. Supondo que o pedido inicial foi feito com 3 unidades de estoque, então no dia 1 se tem 12 unidades de estoque, o estoque máximo determinado. No dia 4, o estoque no final do dia é de 3 unidades, gerando assim um pedido de 9 unidades, as quais são entregues no fim do dia 5 e contabilizados para o início do dia 6, como no dia 5 houve utilização de apenas 2 unidades, então ainda restou 1 unidade, antes da chegada do lote comprado.

No dia 9 a demanda foi muito superior a previsão, foram necessárias 6 unidades ao invés das 3 unidades previstas para consumo. Isto fez com que o pedido fosse realizado no dia 9, passando todo o dia 10 sem disponibilidade do produto, isto é, em ruptura. Assim, parte do dia 9 e todo o dia 10 está em ruptura com relação ao produto, e como a compra é entregue no fim do dia seguinte ao

pedido, então somente no dia 11 é que a loja voltaria a ter unidades disponíveis. No dia 11, não foi demandada nenhuma unidade fazendo com que todas as unidades entregues no fim do dia anterior permanecessem no estoque.

Muitas são as causas para esse tipo de comportamento de demanda. Pode ser um comportamento específico de fim de semana; um dia de mau tempo; ou uma promoção no concorrente. O fato principal é que, com este exemplo didático, tenta-se expor a necessidade da criação de parâmetros ajustados de ponto de pedido, estoques máximos, e controle dos estoques, levando em consideração o tempo de reposição, capacidade de armazenamento e disponibilidade da fonte fornecedora.

Diante deste cenário são apresentadas, a seguir, as formas mais tradicionais de cálculo de reposição de produtos. A quantidade econômica de pedido (EOQ) é a fórmula mais básica para a política de estoque “puxado”, sendo que a mesma está baseada em uma equação de custos, de aquisição e manutenção de estoques (BALLOU, 2006). A expressão matemática que a representa está na equação (2.1)

$$TC = \frac{D}{Q}S + \frac{ICQ}{2} \quad (2.1)$$

onde, TC é o custo do estoque total anual de um dado item, Q é o tamanho do pedido para reposição do estoque, em unidades, D é a demanda anual dos itens ocorrendo a uma taxa determinada e constante no tempo (unidades por ano), S é o custo de aquisição (unidades monetárias por pedido), C é o valor do item no estoque (unidade monetária por item) e I é o custo da manutenção como percentagem do valor do item (% por ano). O primeiro termo da equação é a representação do custo de aquisição, enquanto o segundo representa o custo de manutenção

O termo D/Q representa quantas vezes por ano um pedido de reposição é encaminhado à sua fonte de suprimento e o termo $Q/2$ é o total médio do estoque disponível. Como Q varia em tamanho, enquanto um custo aumenta o outro diminui, com uma observação simples na equação anterior. Se encararmos a equação (2.1) como uma função dependendo de Q , pode-se aplicar a derivada parcial em relação a Q para obtermos o valor de máximo ou de mínimo da função de Q . conforme a equação (2.2) a seguir.

$$\frac{\partial(TC)}{\partial Q} = \frac{\partial}{\partial Q} \left(\frac{D}{Q} S \right) + \frac{\partial}{\partial Q} \left(\frac{ICQ}{2} \right)$$

e igualando a zero para obter o valor ótimo

$$0 = -\frac{DS}{Q^{*2}} + \frac{IC}{2}$$

e portanto

$$Q^* = \sqrt{\frac{2DS}{IC}} \quad (2.2)$$

Portanto esta Quantidade Q^* , apresentada em (2.2), é a quantidade ótima de itens do pedido em que os dois custos estarão em equilíbrio. Deste resultado pode-se chegar ao intervalo ótimo entre pedidos T^* , apresentado na equação (2.3).

$$T^* = \frac{Q^*}{D} \quad (2.3)$$

Da mesma forma, o número ótimo de pedidos anuais N a ser feito é apresentado na equação (2.4).

$$N = \frac{D}{Q^*} \quad (2.4)$$

Estas fórmulas são, em geral, usadas como parte de um procedimento básico de controle de estoques. Partindo desse conceito, pode-se então determinar o ponto de reposição (ROP), como apresentado na equação (2.5).

$$ROP = d.LT \quad (2.5)$$

onde d é a taxa de demanda (supondo conhecida), em unidades de tempo e LT é o prazo médio de entrega (*Lead-Time*), em unidades de tempo. Este controle básico gera um padrão de reposição conhecido com “dente de serra”. Este modelo pode ser

alterado quando o reabastecimento do produto não é instantâneo, gerando uma quantidade Q_p^* , apresentada na equação (2.6).

$$Q_p^* = \sqrt{\frac{2DS}{IC}} \sqrt{\frac{p}{p-d}} \quad (2.6)$$

onde p é a taxa de produção do item. Porém este cálculo só vale quando a taxa de produção é maior que a taxa de demanda ($p > d$).

O controle avançado de estoque “puxado” considera a impossibilidade de determinar com exatidão a demanda e os prazos de entrega. São dois os métodos mais comuns de controle de estoque baseados na probabilidade da ocorrência de uma situação de falta de estoque (BALLOU, 2006):

1. O modelo do “Ponto de Pedido”, que pode ser:
 - Com Demanda Incerta;
 - Com Custos Conhecidos pela Falta de Estoque; e
 - Com Incerteza da Demanda e do Prazo de Entrega.
2. O modelo de “Revisão Periódica”, que pode ser:
 - Com Demanda Incerta;

O modelo do ponto de pedido com demanda incerta considera a distribuição de demanda durante o prazo de entrega, com uma média \bar{x} (representada por d) e um desvio-padrão s_d , os quais podem ser estimados pelo cálculo de um determinado período de distribuição de demanda ao longo da duração do prazo de entrega. Assim, o ponto de reposição é dado, neste caso, pela equação (2.7).

$$ROP = d.LT + z.s_d \quad (2.7)$$

onde z é o número de desvios padrões da média da distribuição encontrada para dar-se a desejada probabilidade de presença em estoque durante o período do prazo de entrega.

O modelo de Ponto de Pedido com Custos Conhecidos pela Falta de Estoque está baseado na probabilidade de ter estoque durante o prazo de entrega, se for permitido o pedido pendente ou se durante uma falta de estoque há perda de

venda, e ainda, no desvio padrão calculado anteriormente e um valor tabelado da distribuição normal e da função perda normal. Para mais detalhes deste modelo consultar Ballou (2006) e/ou Chopra e Meindl (2010). Da mesma forma, o modelo de Ponto de Pedido com Incerteza da Demanda e do Prazo de Entrega, encontra-se detalhado em Ballou (2006).

O Modelo de Revisão Periódica com demanda Incerta exige um estoque ligeiramente maior, sendo, porém os custos adicionais de manutenção mais do que compensados pela redução dos custos administrativos, menores preços ou custos reduzidos de aquisição (BALLOU, 2006). A diferença consiste no fato de que na Revisão Periódica deve-se ter proteção contra flutuações da demanda durante o intervalo entre os pedidos e o momento da entrega, já no Ponto de Pedido a informação da flutuação da demanda durante o prazo de entrega é utilizada no cálculo do estoque de segurança.

Assim, o modelo de Revisão Periódica, embora muito parecido com o modelo do Ponto de Pedido, é realizado da seguinte maneira: O nível de estoque de um item é auditado a intervalos predeterminados, a quantidade a ser colocada em um pedido é a diferença entre uma quantidade máxima M e o total disponível no momento da revisão. Assim o estoque é controlado de acordo com a determinação de T^* e M^* . O cálculo de T^* é o mesmo da equação (2.3), onde Q^* é calculado como na equação (2.2). O cálculo de M^* fica, então, apresentado pela equação (2.8).

$$M^* = d(T^* + LT) + z \cdot s_d \quad (2.8)$$

onde o termo $d(T^* + LT)$ é a média da distribuição para a demanda ao longo do intervalo entre pedidos mais o prazo de entrega, sendo d a taxa média da demanda diária e s_d o desvio padrão da distribuição mencionada. O desvio padrão é calculado para este modelo da seguinte forma apresentada na equação (2.9).

$$s_d = s_{dc} \sqrt{T^* + LT} \quad (2.9)$$

onde s_{dc} é o desvio padrão do consumo de unidades por uma unidade de tempo.

Os métodos de controle de estoque puxado são: o sistema min-max, que consiste em, quando se emite um pedido, ele corresponde ao montante determinado pela diferença entre a quantidade alvo M (estoque máximo) e a quantidade existente

q , quando o nível de estoque atinge o “Ponto de Pedido”. Este sistema é uma variante do modelo de “Ponto de Pedido”, cuja diferença está no fato de a quantidade de compra nem sempre é a mesma por que a quantidade existente q fica abaixo do “Ponto de Pedido”. Neste sistema, pode-se utilizar já um algoritmo de previsão de demanda, por exemplo, baseado em médias móveis. E desta previsão pode-se obter a média e o desvio padrão para cálculo do ponto de pedido e quantidade de reposição.

O sistema ou método de estoque para a demanda, no qual se resume em fazer, em um determinado período, uma previsão da taxa de demanda do item, multiplicando este valor encontrado por um fator que represente o intervalo de revisão, o prazo de entrega do reabastecimento e uma margem de segurança relacionada com a incerteza da previsão e reposição. O pedido é emitido calculando-se a diferença entre o estoque máximo projetado e o estoque atual do produto.

Todos os sistemas ou modelos de reposição de produtos estão baseados em um ponto de pedido, uma quantidade a ser pedida, um estoque máximo projetado (variável ou fixo), uma quantidade de tempo de cobertura de estoque e um método de previsão da demanda do produto. A incerteza ligada a qualquer método de reposição está intimamente ligada a qualidade e acurácia do método de previsão escolhido e pode-se optar por modelos híbridos de reposição baseados em métodos de previsão de demanda mais robustos, visando obter um sistema de reposição que minimiza as falhas e a falta de estoque.

2.2.2.2 As falhas de reposição

Na situação de falhas de reposição pode-se avaliar os impactos da demanda não atendida no relacionamento com seus consumidores. Novaes (2007) afirma que o problema da ruptura não é resolvido trivialmente. As referências citadas pelo autor confirmam os índices, apresentadas anteriormente neste trabalho, em torno de 8% de ruptura em supermercados em “uma tarde típica de venda”. A disputa por espaços nos pontos de venda, a variação temporal da demanda, o nível de serviço oferecido pelo fornecedor, as ineficiências dos varejistas são considerados os principais fatores que geram a ruptura (NOVAES, 2007).

Os prejuízos causados pela falta de estoque são imensuráveis deterministicamente, uma vez que não se pode afirmar se um cliente deixou de comprar outros produtos caso não tenha encontrado um produto que ele buscava. Isto é, caso o cliente não encontre o “produto A” desejado, ele, além de não comprar o “produto A”, por óbvio, pode estar deixando de comprar outros produtos, causando um prejuízo de faturamento de difícil contabilização. Há técnicas de cálculos desses prejuízos divulgadas na literatura e essas técnicas podem trazer uma idéia de quanto foi o impacto devido à ruptura.

Uma alternativa para a solução desse problema pode ser a utilização da parceria entre o fornecedor e o varejista através do *VMI*. Esta estratégia pode trazer ganhos como redução do nível médio de estoque e, como consequência, a redução de custos, redução dos níveis de ruptura de estoque e a diminuição do tempo de entrega (NOVAES, 2007). Porém, pode trazer algumas desvantagens comerciais. O fato de estar atrelado ao fornecedor enquanto durar o contrato, poderá causar multa em caso de desistência de operacionalizar com este fornecedor. O sistema relacionado à gestão de estoques, o qual pode ser uma vantagem competitiva no mercado em caso de bom gerenciamento, com a liberdade de acesso às vendas e informações importantes na empresa varejista pode resultar em uma submissão aos preços do fornecedor, gerando assim uma desvantagem em caso de mais de um fornecedor para o mesmo produto ou produtos similares.

Dentre estas causas da ruptura citadas e das técnicas de gerenciamento de estoque comentadas e encontradas na literatura, percebeu-se uma oportunidade de mudança de visão no formato de modelagem da reposição quando se utiliza técnicas de previsão mais robustas para a reposição de produtos. Em todas as formas do cálculo do ponto de reposição de produtos consultadas, o fator da previsão de demanda e, por conseguinte, a determinação do método de previsão utilizado, está presente. É justamente no algoritmo de previsão de demanda que o fator incerteza está baseado e quanto melhor for a previsão melhor pode funcionar o modelo de reposição, pois a incerteza será menor.

Com isso, ao se apresentar o modelo de reposição proposto neste trabalho, pretende-se propor também a utilização de um algoritmo de previsão de demanda, baseada em séries temporais geradas pelas quantidades de venda de cada produto, mais robusto. Há vários algoritmos para previsão de séries temporais que estão na ponta do desenvolvimento numérico-computacional como, por exemplo, o *Support*

Vector Machine – Regression (SVR) e as Redes Neurais Artificiais (RNA) além dos algoritmos consagrados na literatura, como o método estatístico de Box & Jenkins (Método ARIMA).

2.2.3 Níveis de Rupturas

Um dos problemas mais críticos que impedem a qualidade das operações realizadas e, conseqüentemente, a excelência no atendimento aos clientes é a ruptura de produtos nas gôndolas das lojas. A ruptura, ou quebra de estoque, é a situação em que um produto comercializado pela empresa não se encontra disponível na área de vendas ao consumidor no momento da compra. Estimativas dos níveis de ruptura têm constantemente ultrapassado a média de 8% no varejo e, apesar dos esforços, esse valor tem permanecido elevado por um longo período de tempo. Entre as várias causas estão a proliferação de produtos, redução do ciclo de vida e a falta de coordenação da cadeia de suprimentos.

No Brasil, são poucos os estudos acadêmicos em relação às causas da ruptura e as possíveis soluções para evitar este fato. Uma pesquisa realizada pela ACNielsen Brasil, em julho de 2004, analisou as principais causas e a reação do consumidor quando este se deparava com a falta de produto nas gôndolas. Os resultados obtidos nesta pesquisa foi uma taxa média de ruptura de 8%. Além disso, o estudo conclui que as principais oportunidades de melhorias estavam entre o CD do varejo e a gôndola da loja.

Em outra pesquisa, do Núcleo de Pesquisas e Publicação (ESPM – São Paulo) (VASCONCELLOS; SAMPAIO; PASTORE, 2007), constatou em pesquisa com os gestores de supermercados que o nível de ruptura médio dos supermercados paulistas é de 8,3% com um desvio padrão de 6,8%. Esta pesquisa também revelou que, baseado nos seus levantamentos de dados, o nível de ruptura de supermercados compactos é de 9,1%; de supermercados convencionais é de 8,5% e a de hipermercados é de 7,1%. Tais percentuais podem ser observados na Figura 2.2. Ambas as pesquisas mostram resultados semelhantes e destacam a importância de serem realizados estudos mais profundos objetivando metodologias e estratégias que busquem soluções para a diminuição desses níveis de ruptura.




FIGURA 2.2 – NÍVEIS DE RUPTURA - PESQUISAS BRASILEIRAS
 FONTE: O AUTOR (2011).

Para exemplificar o problema da ruptura no Brasil, a Rede de Supermercados Unicompra, de Alagoas, divulgou em janeiro de 2011, no Blog varejomix³, que sua ruptura foi baixada de 12% para 8% devido às correções realizadas a partir dos diagnósticos das causas. A Unicompra informatizou a rede por meio de um software de gestão que auxilia os compradores a acompanhar as vendas e o estoque dos produtos e permite realizar pedidos mais realistas.

Na América Latina, o estudo sobre ruptura também é realizado considerando as causas, níveis e possíveis soluções para a ruptura encontrada nos supermercados. No Chile, o *Departamento de Ingenieria Industrial (DII)*, da *Universidad de Chile, Facultad de Ciencias Fisicas y Matematicas*, em setembro de 2004, fez estudos sobre o setor de supermercados chilenos. Este estudo tinha os seguintes objetivos: estudar o nível de mercadorias faltantes nas gôndolas; entender as causas que originam este fato e; analisar o comportamento dos clientes perante a esta falta. No fim do estudo foram feitas recomendações para minimizar o problema.

Os resultados obtidos na pesquisa feita nos supermercados chilenos mostram que os produtos de alta rotatividade possuem um nível de 12% de ruptura, enquanto os produtos de média e baixa rotatividade têm, respectivamente, um nível de 17% e 27% de ruptura. Mostra-se nesta pesquisa que, quanto maior a loja do supermercado, menor é o índice de ruptura médio, sendo que as lojas chamadas de conveniência possuem uma média de 18,5% de ruptura, supermercados e hipermercado, possuem níveis de 15,5 % e 9,5% de ruptura, respectivamente, e que

³ < <http://varejomix.blogspot.com/2011/01/com-tecnologia-unicompra-reduz-ruptura.html>>.
 Acesso em 05/07/2011

os mega-mercados possuem um nível médio de 9,5% de ruptura. O estudo conclui mostrando que os estoques virtuais, diferença entre a quantidade contabilizada no sistema de controle e a quantidade real nas prateleiras, são as maiores causas para a falta de produto nas gôndolas das lojas.

Já na Colômbia foi desenvolvido um levantamento de dados de setembro de 2002 a agosto de 2004, medindo a ruptura todos os dias (BARAJAS, 2004). Os resultados obtidos mostram uma tendência de decrescimento nos níveis de ruptura a cada seis meses, onde no segundo semestre de 2002, obteve-se um nível de 13,2%, passando para 11,8%, depois para 11,1%, voltando para 11,8% e finalizando o levantamento de dados no segundo semestre de 2004, encontrando uma taxa de 9,2% de ruptura, conforme pode ser observado na Figura 2.3. A pesquisa feita no mercado colombiano mostra que as principais causas da ruptura são: não reabastecimento da gôndola; pedido de reposição insuficiente e não entrega do produto pelo fornecedor. Barajas sugere uma integração maior entre os supermercados e fornecedores e a utilização do *benchmarking* em boas práticas operacionais para pontos de venda.




FIGURA 2.3 – NÍVEIS DE RUPTURA - PESQUISAS COLOMBIANAS
FONTE: ADAPTADO DE BARAJAS (2004).

Na argentina, De Luca (2004), inicia um processo de comparação dos níveis de ruptura entre os anos de 2003 e 2004. Constata que a taxa encontrada em 2003 que foi de 17,15% caiu para 12,87% em 2004. De Luca separa a taxa de ruptura em quatro causas principais: fornecedor; compras; logística e distribuição e, também, local de venda. Ele mostra que o fator que mais influencia na taxa de ruptura são as operações de reposição no ponto de venda e recomenda que seja feita a aplicação de ferramentas de otimização para auxiliar no planejamento de reposição, medições

contínuas, melhorias nas práticas logísticas e planejamento conjunto com fornecedores. A conclusão do trabalho destaca a importância de diminuir o nível de ruptura já que, segundo a pesquisa realizada, 35,85% dos clientes procuram a concorrência para efetuar suas compras quando não encontram certo produto na gôndola.

O trabalho de Ferraro e Fournier (2004), sobre a empresa Unilever, faz um levantamento sobre ruptura e como esse problema afeta a fidelização do cliente às marcas e à satisfação dos clientes ao realizar suas compras. Indica que a medição da ruptura pode ser realizada por auditores externos, com informações objetivas e fluxo de informação eficiente para a realização dos planos de ação, ou internos, com a identificação dos produtos mais críticos em relação à ruptura e a tentativa de diagnosticar antecipadamente a possível ruptura para se tomar as medidas apropriadas.

Os resultados apresentados foram de uma taxa de 12,76% de ruptura para produto da divisão *HPC (Home & Personal Care / Divisão de Higiene e Beleza)* e 5,94% para produtos alimentícios, apresentados na Figura 2.4. O trabalho apresenta na conclusão a idéia de que a integração entre fornecedor e empresa, caracterizada pelo sistema *VMI (Vendor Management Inventory – Estoque gerido pelo fornecedor)*, é a chave para a obtenção do êxito para diminuição da ruptura que, se reduzida, gera maiores vendas e resultados mais sustentáveis com o tempo.




FIGURA 2.4 – NÍVEIS DE RUPTURA – EMPRESA UNILEVER
FONTE: ADAPTADO DE FERRARO E FOURNIER (2004).

Estudos norte-americanos sobre os níveis de ruptura (em inglês, *out-of-stocks - OOS*) feitos por Thomas W. Gruen, professor de *marketing* da Universidade de Colorado, em Colorado Springs, EUA (GRUEN, 2007), apresentou uma discussão detalhada a respeito dos níveis de ruptura dos principais mercados

mundiais. Ele apresenta as taxas de ruptura de quatro localidades mundiais, os EUA, com 7,9% de ruptura, a Europa, incluindo leste europeu, com 8,6%, outras regiões importantes, como América Latina, com 8,2%, e dados encontrados através da internet de outras localidades diversas do mundo (não explicitadas no trabalho) com taxas de 8,3% em média, apresentadas na Figura 2.5. Afirma, ainda, que em produtos em promoções, a taxa de ruptura nos EUA sobe de 7,9% para 17,1%.




FIGURA 2.5 – NÍVEIS DE RUPTURA – PESQUISAS MUNDIAIS
FONTE: ADAPTADO DE GRUEN (2007).

O trabalho apresenta também que 55% dos produtos em ruptura demoram mais de um dia para serem repostos nas lojas, assim, encontra-se em média um produto faltante na gôndola a cada 13 produtos, isto é, cerca de 7,7% dos produtos comercializados nos supermercados americanos. O trabalho é concluído com sugestões para amenizar o problema da ruptura, entre elas, medir e avaliar constantemente o nível de ruptura, identificando as causas, aplicando e incrementando as soluções encontradas continuamente, observando a situação em que o supermercado se encontra.

No problema aqui abordado para ilustrar a metodologia proposta, encontrou-se um nível de ruptura que atingia quase 15% em alguns casos e nunca diminuía de 8%, mesmo nas lojas mais eficientes da rede. A ruptura considerada e medida neste trabalho foi a ruptura CD-Loja, isto é, produtos que estão no CD e entram em ruptura nas lojas por falta de uma reposição mais eficiente, sendo desconsiderada a ruptura causada pela reposição de produtos diretamente do fornecedor. O nível de

ruptura encontrado e citado é relacionado somente aos produtos centralizados (recebidos via entrega centralizada), objetos de estudo neste trabalho.

2.2.4 Causas da Ruptura

A ruptura é cada vez mais reconhecida como um problema crítico, tanto por pesquisadores como práticos. Deve ser gerenciada como uma combinação de esforços para reduzir o número de ocorrências, minimizando a falta do produto nas gôndolas e, ainda, oferecendo compensações para alterar a reação do consumidor de, por exemplo, deixar a loja quando a ruptura for inevitável e/ou demasiadamente dispendiosa de ser eliminada.

As causas para ruptura nos EUA estão distribuídas, segundo Gruen (2007), da seguinte forma: 34% por problemas nas previsões de vendas, 25% por falhas na reposição do estoque, 14% pela não entrega de fornecedores, 13% por falhas nos pedidos para os fornecedores, 10% por problemas no CD e 4% por outras causas, como ilustrado na Figura 2.6.




FIGURA 2.6 – CAUSAS DA RUPTURA NOS EUA
FONTE: ADAPTADO DE GRUEN (2007).

Os principais estudos brasileiros sobre a ruptura mostram resultados relevantes também em relação às razões para a ausência do produto na área de venda. Os dados são, em geral, resultados de pesquisas feitas com os gerentes dos setores dos supermercados e mostram que o atraso na entrega do CD à loja é a principal causa para esta falta de mercadoria, seguido pelo não reabastecimento do produto na gôndola. Estas duas principais causas são responsáveis por 42,6% da geração da ruptura. A Figura 2.7 apresenta os resultados das cinco principais

causas da ruptura, sendo ocultadas as diversas outras causas que, juntas, somam 35,8%, mas que individualmente não possuem grande relevância.




FIGURA 2.7 – CAUSAS DA RUPTURA - PESQUISAS BRASILEIRAS
FONTE: ADAPTADO DE ACNIELSEN (2004)

Enquanto a literatura internacional é rica em pesquisas nestas duas vertentes, a literatura brasileira é carente de informações sobre a ruptura em seu mercado. Quando ocorre a ruptura, em 45% dos casos os consumidores substituem seus produtos, em 31% trocam de lojas, em 14% dificilmente retornam, isto é, ficam na dúvida se trocam ou não de loja, e em 10% dos casos os clientes têm outras reações, as quais não foram explicitadas no trabalho de Vasconcellos, Sampaio e Pastore (2007), como mostrado na Figura 2.8




FIGURA 2.8 – REAÇÕES DOS CLIENTES FRENTE A RUPTURA NOS SUPERMERCADOS
FONTE: ADAPTADO DE VASCONCELLOS, SAMPAIO E PASTORE (2007).

A ruptura de gôndola foi, é, e provavelmente sempre será um importante problema gerencial a ser resolvido.

2.2.5 Decisões sobre políticas de estoques

O gerenciamento de estoques está relacionado com basicamente duas filosofias: o conceito de “puxar” e o conceito de “empurrar” (BALLOU, 2006). O primeiro está ligado com a alocação de suprimentos com base na previsão individual de cada produto, o segundo está relacionado com a reposição de estoques em quantidades baseadas na necessidade do armazém a ser repostado. O conceito mais amplamente utilizado é um híbrido entre as duas filosofias, e neste caso, são consideradas tanto a previsão de consumo do produto/ suprimento e a necessidade/capacidade do armazém em relação a este produto, determinando assim uma quantidade e um momento para esta reposição.

A questão mais preocupante em um sistema de reposição é o quanto e quando se deve fazer esta reposição. Esta incerteza está relacionada com o cálculo da quantidade de estoque de segurança, o qual, dependendo da política e do controle de estoque da empresa, pode ser realizado de diversas formas, dependendo do nível de serviço desejado. O estoque de segurança deve ser calculado de forma que garanta a disponibilidade do produto durante certo período de tempo.

Em geral, o estoque de segurança é uma quantidade que deve ser mantida para satisfazer uma demanda que ultrapassa a quantidade prevista para determinado período. A existência deste deve-se à incerteza da demanda e da previsão utilizada (BOWERSOX, *et al.*, 2007).

2.2.6 O planejamento de estoques

O planejamento de estoque consiste em determinar quando e quanto pedir. A maioria dos autores clássicos, que tratam deste tema (BALLOU, 2006) (CHOPRA

e MEINDL, 2010) (BOWERSOX, *et al.*,2007), divulgam o conceito de ponto de reposição como sendo a multiplicação de uma taxa de demanda, em unidades por tempo e do prazo médio de entrega, em unidades de tempo. Neste caso, tem-se um valor em unidades do produto, sendo que se a quantidade em estoque do produto disponível atingir esta quantidade, o ponto de reposição, então é preciso fazer um pedido de um lote econômico adequado de compra.

Este modelo básico de reposição pode ser aprimorado de acordo com a complexidade de informações pertinentes que se deseja incorporar ao modelo. Por exemplo, pode-se querer incorporar ao modelo a incerteza da demanda, o prazo de entrega, os custos conhecidos por falta de estoque, o giro de estoques no caso de controle agregado, tarifas de transportes, custos por pedidos, médias de vendas, incertezas na duração do ciclo de atividades, entre outros fatores.

3 TÉCNICAS PARA PREVISÃO DE VENDAS

O processo de previsão de demanda constitui-se em uma das atividades mais importantes de um sistema de produção e, diante dessa perspectiva, é considerada a base do processo de planejamento. Toda organização deve proceder de maneira cuidadosa e responsável em relação ao processo em questão, pois uma previsão precária pode acarretar excesso de estoque, reduções desnecessárias de preços ou perda de vendas devido à falta de produtos.

Para aumentar a vantagem competitiva comercial em um ambiente de constantes mudanças, os gestores de uma organização devem tomar a decisão correta no momento certo, com as informações que estiverem disponíveis. Uma previsão acertada tem papel fundamental nesse processo.

Compreendendo melhor o comportamento do consumidor e sua resposta às alterações nos fatores controláveis que o varejista articula, os gestores podem prever os resultados de suas ações e obter dados de diagnósticos para se suprir de informações que permitam ações acertadas no futuro. Inúmeras técnicas de previsão têm sido desenvolvidas na tentativa de melhor solucionar o problema de previsão de vendas. Tais técnicas podem ser divididas, conforme já comentado, em dois grupos principais de abordagem: qualitativa e quantitativa. Dentro de cada grupo, várias subdivisões distintas já foram propostas na literatura para classificar as técnicas de previsão, sendo que uma delas é apresentada na Figura 3.1.

Uma série temporal é uma seqüência de valores, ordenados no tempo, de uma variável de interesse particular, uma série temporal, também denominada série histórica, é uma seqüência de dados obtidos em intervalos regulares de tempo durante um período específico (MORETTIN e TOLOI, 1985). Modelos de séries temporais realizam previsões baseadas em uma série de dados observados em intervalos de tempo regulares, buscando padrões no passado para prever o futuro. Esse tipo de modelagem é especialmente útil quando há pouco conhecimento da base teórica sobre o processo em que os dados foram gerados ou quando a complexidade da explicação sobre o processo é muito alta, como no caso de previsão de vendas no varejo.

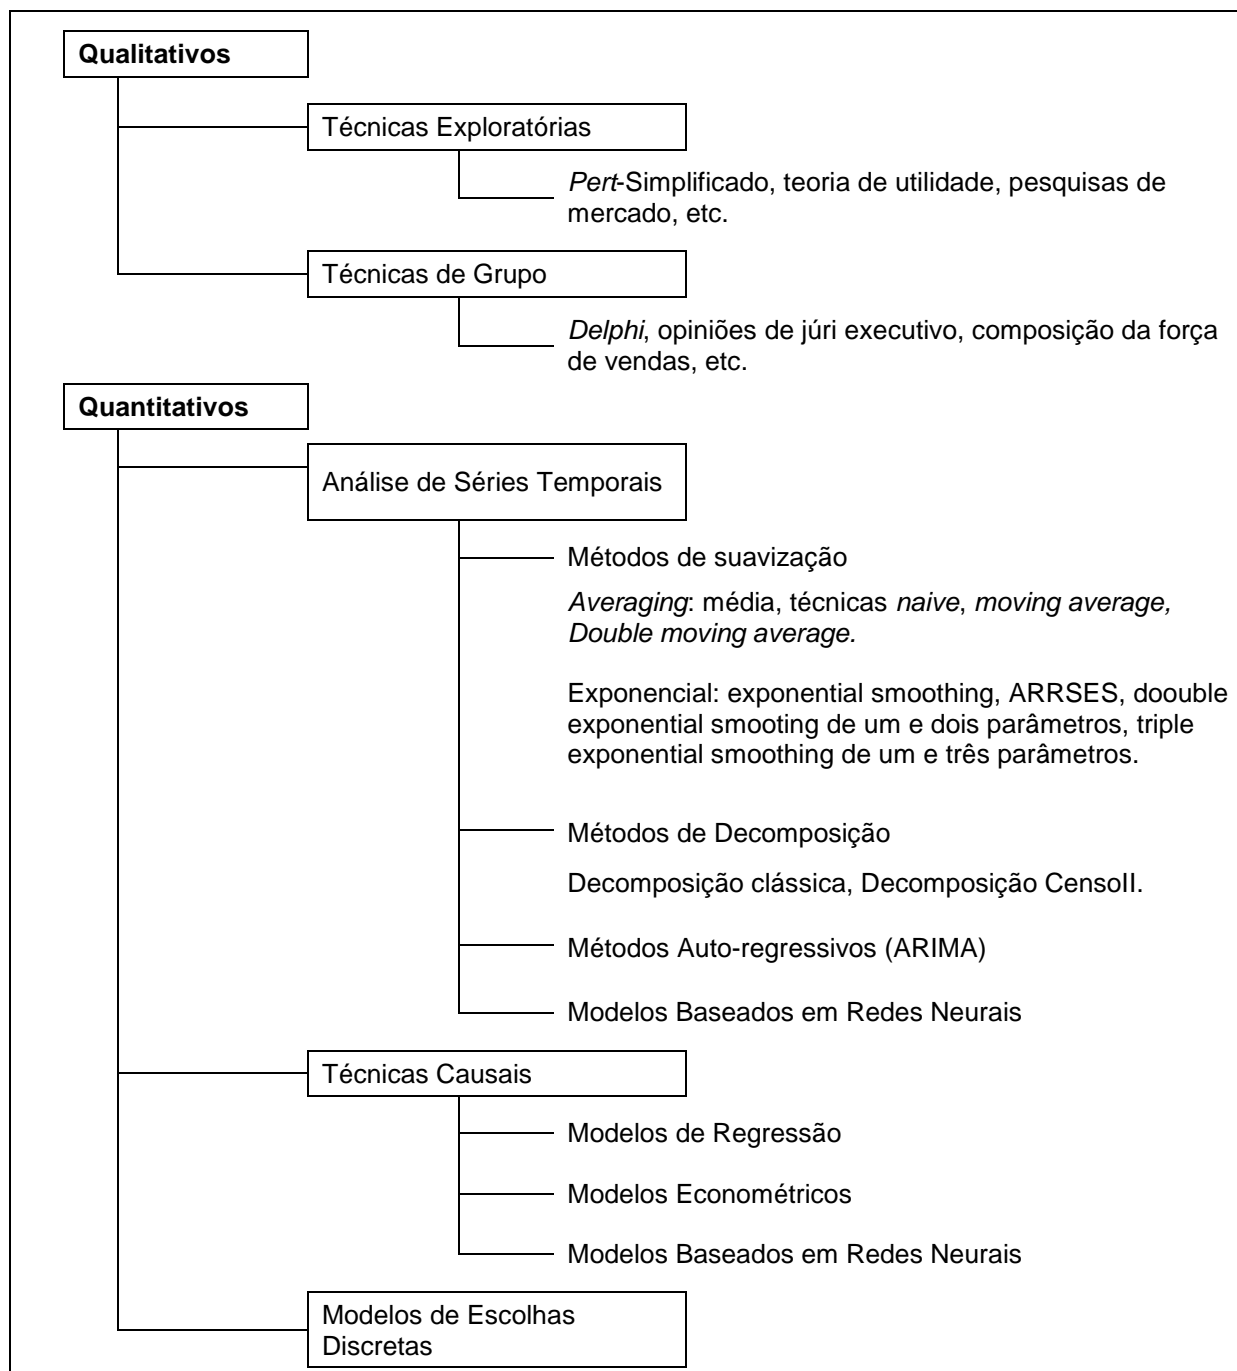


FIGURA 3.1 – ESQUEMA DE CLASSIFICAÇÃO DE TÉCNICAS DE PREVISÃO
 FONTE: ADAPTADO DE PASSARI (2003)

Apesar de sua grande aceitação, as técnicas de previsão de séries temporais possuem sérias limitações. A mais visível delas é o fato das causas que agem sobre as variáveis previstas serem completamente ignoradas. Todas as forças externas, como fatores econômicos, esforços de *marketing*, ações dos competidores e assim por diante, são desprezadas. Outra deficiência é que os padrões históricos que geraram as séries mudam com o tempo, e algumas técnicas não detectam tais

mudanças. Assim, estas técnicas podem resultar previsões com baixa acurácia, especialmente em longo prazo.

Entretanto, para obter informações suficientes para elaborar um planejamento de ações logísticas e obter um valor futuro de venda mais próximo do real, algumas técnicas de previsão de séries temporais têm demonstrado grande aplicabilidade e excelentes resultados. A preocupação, nesta aplicação, é prever com certo grau de precisão o que vai acontecer e não porque vai acontecer. Com isso, as técnicas mais avançadas de previsão de séries temporais, os algoritmos matemáticos e estatísticos, podem ser implementados, mesmo que o esforço computacional seja muito grande, de modo a encontrar valores futuros de venda que indiquem como prever ações e antecipar as necessidades do mercado.

A literatura é vasta quanto à utilização de algoritmos de previsão de séries temporais. Nela encontram-se evidências de que, mesmo não considerando as variáveis de mercado, podem-se ajustar os modelos de modo a compreender e prever períodos de sazonalidades, tendências a queda ou elevação de venda, comportamento de clientes e outras características mercadológicas. O avanço das técnicas baseadas em Redes Neurais, por exemplo, é um exemplo de que se pode prever um valor de venda com qualidade e boa precisão gerando uma referência para antecipação das ações operacionais.

3.1 TÉCNICAS ESTATÍSTICAS

A estratégia de reposição de produtos deve ser efetiva no suprimento das lojas, porém deve ser controladas de modo a não super estocá-las. A grande maioria dos controladores de estoque comercializados e usados nas empresas possui um sistema de previsão simplificado, em geral, utilizando métodos estatísticos, como o “Alisamento Exponencial Simples” e as “Médias Móveis”. Estes métodos são utilizados para a previsão de séries temporais e são de fácil entendimento e aplicação, para séries temporais com alta instabilidade, porém, estes métodos, acabam por não satisfazer o objetivo de prever com qualidade a série estudada. A previsão da demanda é uma etapa-chave dentre as etapas de uma cadeia de suprimentos devido à complexidade e incertezas intrínsecas às suas atividades.

Uma estratégia de reposição de produtos baseada nesses métodos pode ocasionar falhas de suprimento de produtos, seja pela falta ou excesso de estoque.

Isso pode ocorrer com grande facilidade devido à característica de vendas dos produtos no setor supermercadista, onde a instabilidade de vendas é muito grande (WANKE, 2003). A sazonalidade, o preço do produto, o dia da semana, a concorrência, o atendimento e as promoções são componentes que influenciam diretamente no comportamento de vendas (FIGUEIREDO, 2006). A série temporal de vendas é muito sensível a qualquer um desses aspectos fazendo com que um método mais robusto deva ser utilizado para a previsão de vendas.

Os métodos tradicionais são aplicados quando se consegue identificar a características de demanda e a composição do seu componente sistemático (CHOPRA e MEIDL, 2010), (BOWERSOX et al., 2007) (NOVAES, 2007). O método mais conhecido e simples é o chamado Médias Móveis, onde se calcula a média de demanda dos n períodos anteriores e a cada nova ocorrência atualiza-se esse média deslocando o cálculo em uma unidade de tempo para frente e obtendo a nova previsão.

O método de Alisamento Exponencial Simples incorpora a informação da previsão do período anterior e a ocorrência do período anterior, fazendo uma combinação convexa dessas duas informações. A estimativa do método está no ajuste do fator da combinação convexa calculada, a chamada constante de alisamento. Para a aplicação deste método a demanda não pode possuir tendência ou sazonalidade para se obter bons resultados (CHOPRA e MEIDL, 2010).

O Método de Holt é o alisamento exponencial corrigido pela tendência, e se o alisamento exponencial for corrigido pela tendência e sazonalidade tem-se o método de Winter. Ambos métodos necessitam da estimativa de coeficientes de influência dessas características e a determinação destes coeficientes, em geral, são feitas por interpretações do decisor sobre a influência dos dados observados recentemente (NOVAES, 2007).

Os métodos de decomposição as série temporal possui uma grande aceitação em sua aplicação devido a sua simplicidade matemática e precisão de informações. Este método decompõe a série histórica em 4 fatores: tendência, sazonalidade, ciclo e ruído branco ou índice residual. Na prática, o valor previsto, que é a multiplicação deste 4 índices, pode se resumir aos dois primeiros, Tendência e sazonalidade. Para a tendência, em geral, estima-se o valor através do clássico

modelo dos Mínimos Quadrados, já para a sazonalidade o valor é calculado como o quociente da demanda real em relação a demanda média, num determinado período (BALLOU, 2006).

A Análise de Regressão Múltipla é uma técnica estatística que ajuda a determinar o grau de associação entre um número de variáveis selecionadas e a demanda. A informação sobre as variáveis preditivas é convertida em uma equação de regressão a fim de proporcionar uma previsão de demanda. Akabay e Wang (1995), Wanke (2004), Moreira (2008) e Junges e Fontana (2011) são trabalhos que utilizaram e discutiram a aplicação da Regressão Múltipla para a previsão de séries temporais.

3.2 REDES NEURAIS ARTIFICIAIS (RNA)

Técnicas de programação elaboradas como as de Inteligência Artificial, vêm sendo empregadas na resolução de novos e antigos problemas, pois fornecem soluções que têm apresentado resultados bastante satisfatórios, seja no produto final, como na execução da tarefa, trazendo economia de tempo e recursos computacionais.

Dentre estas técnicas, as RNA se destacam, pois apresentam características tais como: capacidade de aprendizado e generalização. São empregadas no reconhecimento de padrões; composição musical; processamento de sinais, digitais e imagens; otimização; visão computacional; robótica e previsão de séries temporais.

3.2.1 Neurônio Biológico e Artificial

Uma RNA é um modelo computacional que compartilha algumas das propriedades do cérebro: consiste de muitas unidades simples trabalhando em paralelo sem um controle central. As conexões entre unidades possuem pesos numéricos que podem ser modificados pelo elemento de aprendizado (Russell &

Norvig, 2004). A essas unidades damos o nome de neurônios e as suas conexões, sinapses. As RNA são similares as do cérebro humano em, basicamente, dois aspectos (Haykin, 2001):

- A experiência é a fonte do conhecimento adquirido e
- O conhecimento adquirido é armazenado nas sinapses.

O neurônio, célula constituinte do cérebro, ilustrado pela Figura 3.2, é composto por um corpo celular chamado “soma”, onde se encontra seu núcleo e por axônios e dendritos. O axônio, uma fibra nervosa de superfície lisa com poucas ramificações e maior comprimento, é responsável pela transmissão na comunicação com os outros neurônios. Os dendritos, que têm aparência de árvores, possuem superfície irregular e muitas ramificações, atuam como receptores nesta comunicação.




FIGURA 3.2 – NEURÔNIO BIOLÓGICO: OS CONSTITUINTES DA CÉLULA
 FONTE: DIAS (2007)

Tal comunicação ou interação, sinapse, é caracterizada por um processo químico no qual são liberadas substâncias transmissoras que se difundem tal junção sináptica entre neurônios, o que causa aumento ou queda no potencial elétrico do neurônio receptor. Resumindo, uma sinapse é a conexão entre neurônios o que implica em excitação ou inibição do neurônio receptor (Haykin, 2001).

De forma análoga, um neurônio artificial apresenta as mesmas características. A Figura 3.3 mostra um modelo onde podem ser vistos: sinapses representadas pelas entradas e pesos sinápticos, somatório e função de ativação. Cada sinapse é caracterizada por um estímulo de entrada multiplicado pelo seu peso sináptico correspondente. Depois desta multiplicação, cada sinal de entrada é

somado e o resultado é então, aplicado a uma função de ativação que restringe a saída do neurônio a um intervalo $[0, 1]$ ou $[-1, 1]$, dependendo da função de ativação aplicada. O neurônio artificial pode ser descrito pela equação (3.1) (Haykin, 2001):

$$y_k = \varphi \left(\sum_{i=1}^n x_i w_{ki} \right) \quad (3.1)$$

onde y_k é a saída do neurônio; φ é a função de ativação; x_1, x_2, \dots, x_n são os sinais de entrada do neurônio; e $w_{k1}, w_{k2}, \dots, w_{kn}$ são os pesos sinápticos do neurônio em questão (neurônio k).

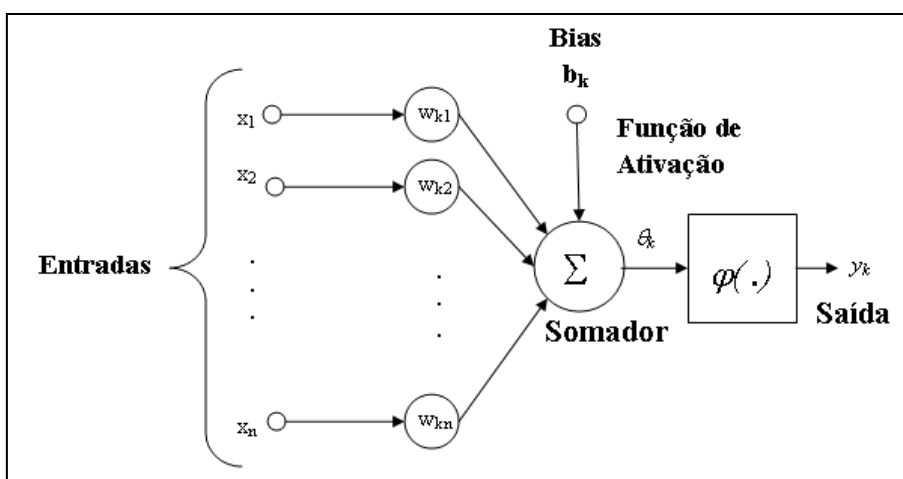


FIGURA 3.3 – NEURÔNIO ARTIFICIAL
FONTE: ADAPTADO DE HAYKIN (2001)

Portanto, o neurônio artificial imita o funcionamento do neurônio biológico por meio das entradas, pelas sinapses e pela função de ativação que simula o processo químico que libera substâncias químicas que excitarão ou inibirão os próximos neurônios.

3.2.2 Funções de Ativação

Cada neurônio realiza um processamento simples: recebe uma entrada e computa um novo nível de ativação (Russell e Norvig, 2004). Este processamento é

composto por duas etapas: na primeira, cada entrada x_i do neurônio é multiplicada pelo peso sináptico correspondente w_{ji} (peso da entrada i do neurônio j). O resultado de cada multiplicação é então somado. Na segunda etapa a soma é aplicada a uma função de ativação f , obtendo-se a saída do neurônio (y), conforme (3.2).

$$y = f(x_i w_{ji}) \quad (3.2)$$

A função de ativação deve simular as características não lineares do neurônio biológico. As funções mais utilizadas são:

Função Linear: É uma função linear da forma (3.3).

$$f(x) = ax \quad (3.3)$$

Função Degrau: É uma função utilizada para valores binários e é da forma (3.4).

$$f(x) = \begin{cases} 1 & \text{se } x > 0 \\ 0 & \text{se } x \leq 0 \end{cases} \quad (3.4)$$

Função Sigmóide: Também chamada de função logística, é uma função contínua que permite a transição gradual entre os dois estados. É dada por (3.5).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.5)$$

Função Tangente Hiperbólica: É uma função sigmóide que varia no intervalo $[-1, 1]$. É dada por (3.6).

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (3.6)$$

Função Gaussiana: A saída do neurônio produzirá resultados iguais para aqueles valores de potencial de ativação $\{u\}$ que estejam posicionados a uma

mesma distância de seu centro, sendo que a curva é simétrica em relação a este. É dada por (3.7) (SILVA, *et. al*, 2010).

$$f(x) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (3.7)$$

onde c é um parâmetro que define o centro da função gaussiana e σ denota o desvio padrão associado à mesma, isto é, o quão espalhado (dispersada) está a curva em relação ao seu centro.

3.2.3 Topologia das RNA

Existe uma grande variedade de redes, cada uma produzindo diferentes resultados. Elas podem ser classificadas basicamente em alimentadas a frente (*feed-forward*) e recorrentes (Russell & Norvig, 2004). Nas redes *feed-forward* os neurônios estão dispostos em camadas, podendo haver redes com uma única camada e redes com múltiplas camadas. As redes *feed-forward* são inerentemente acíclicas, ou seja, o sinal é propagado somente da entrada para a saída da rede. Também são chamadas redes sem memória.

Nestas redes do tipo *feed-forward*, as redes multicamadas se distinguem das redes de camada única pela presença de uma ou mais camadas ocultas. As entradas de um neurônio são as saídas dos neurônios da camada anterior, portanto não há ligação entre neurônios de uma mesma camada. Uma rede *feed-forward* pode ser representada pela notação $e - o_1 - o_2 - \dots - o_n - s$, onde e representa o número de neurônios nas camadas de entrada, o_1, o_2, \dots, o_n representam o número de neurônios nas camadas ocultas e s o número de neurônios na camada de saída. A Figura 3.4 ilustra uma rede *feed-forward* de camada única e uma rede multicamada 4-2-1 (Haykin, 2001; Russell & Norvig, 2004).




FIGURA 3.4 – EXEMPLOS DE REDES *FEED-FORWARD*
 FONTE: ADAPTADO DE HAYKIN (2001)

Perceptron e o MLP (*Multi-Layer Perceptron*) são, respectivamente, exemplos de modelos de rede de camada única e rede de múltiplas camadas.

Ao contrário das redes *feed-forward*, as redes recorrentes possuem laços de realimentação, ou seja, a saída de um neurônio pode ser entrada para outro de uma camada precedente ou, no caso de auto-realimentação, para o próprio neurônio. As redes recorrentes, chamadas de redes com memória, não possuem organização rígida (assim como nas redes do tipo *feed-forward*) e seus neurônios têm liberdade para se ligar a qualquer outro neurônio (Haykin, 2001; Russell & Norvig, 2004). A Figura 3.5 ilustra uma rede recorrente.

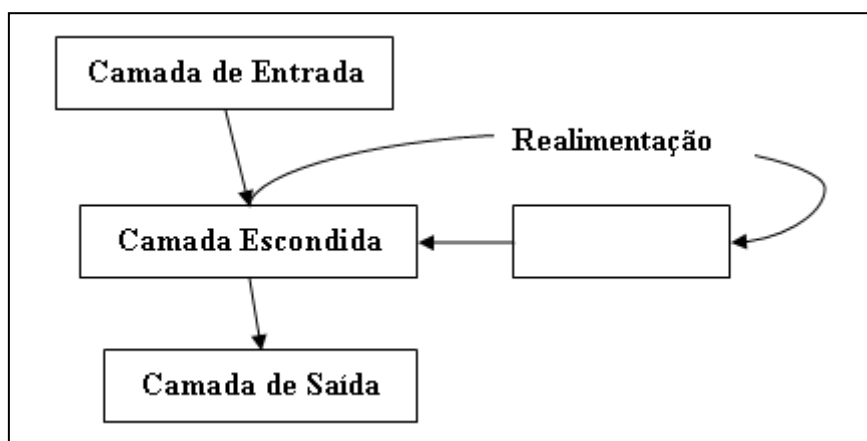


FIGURA 3.5 – ESQUEMA DE UMA REDE RECORRENTE
 FONTE: DIAS (2007)

Como exemplos de modelos de redes recorrentes temos a rede de *Elman*, rede de *Hopfield*, rede de *Jordan* e *NARX*, dentre outras (Kohonen, etc.).

3.2.4 Aprendizado das RNA

O processo de aprendizagem ocorre através de um processo iterativo de ajuste dos parâmetros livres, pesos sinápticos, por estimulação do ambiente (Haykin, 2001). Os paradigmas de aprendizado são: aprendizado supervisionado e aprendizado não supervisionado, descritos a seguir.

Aprendizado Supervisionado: também chamado de aprendizado “com professor”. Esta forma de aprendizado se baseia em um conjunto de exemplos de entrada-saída que é apresentado à rede. A partir da entrada, a rede realiza seu processamento e a saída obtida é comparada com a saída esperada (desejada). Espera-se que seja a mais próxima possível; caso contrário, um processo de ajuste de pesos é aplicado buscando-se um erro mínimo ou aceitável. O algoritmo de aprendizado supervisionado mais comum é o algoritmo *backpropagation* (retro propagação do erro) (Haykin, 2001).

Aprendizado não supervisionado: é caracterizado pela ausência de algum elemento externo supervisor, ou seja, um padrão de entrada fornecido permite que a rede livremente escolha o padrão de saída a partir das regras de aprendizado adotadas. Pode ser:

- **Aprendizado por reforço:** consiste no mapeamento entrada-saída através da interação com o ambiente e;
- **Aprendizagem auto-organizada:** a partir de métricas de qualidade do aprendizado ocorre a otimização dos parâmetros livres da rede.

Os algoritmos de aprendizado não supervisionado mais importantes são: o algoritmo de *Hopfield* e mapas auto organizáveis de *Kohonen* (Haykin, 2001).

3.3 REDE NEURAL DE FUNÇÃO DE BASE RADIAL

As Redes Neurais de Base Radial (RBF ou *Artificial Neural Networks of Radial Basis Functions*) são RNA com 3 camadas (entrada, escondida e saída) que não são treinadas por retropropagação do erro (*backpropagation*) e que não têm

unidades de processamento com função de ativação do tipo sigmoidal. Redes que funcionam de acordo com esta estratégia, utilizam unidades com campos receptivos locais (*local receptive fields*), nos quais as unidades que recebem entradas diretamente da entrada do sistema estão habilitadas a “ver” apenas parte destas entradas.

Esta abordagem emprega, na maioria dos casos, treinamento supervisionado e não-supervisionado. As redes são muito empregadas como interpoladores / aproximadores e em tarefas de classificação. Algumas extensões do método são aqui mostradas. Esta abordagem é inspirada na propriedade de alguns neurônios biológicos chamada de resposta localmente sintonizada (*locally tuned response*). Tais células nervosas respondem seletivamente a um intervalo finito do espaço de sinais de entrada.

Os modelos de RBF de hoje se diferenciam dos primeiros, pois são de natureza adaptativa que permite a utilização, em muitas situações, de um número relativamente menor de unidades de processamento localmente sintonizadas, os chamados centróides.

3.3.1 Arquitetura das redes RBF

As redes RBF são redes de alimentação direta (*feedforward*) consistindo tipicamente de três camadas: entrada, escondida e saída. A primeira apenas recebe as entradas. As unidades de processamento da camada escondida são localmente sintonizáveis, os centróides. As unidades na camada escondida são totalmente conectadas àquelas da camada de saída. Esta última possui unidades lineares. Na Figura 3.6 está uma ilustração de uma RBF.

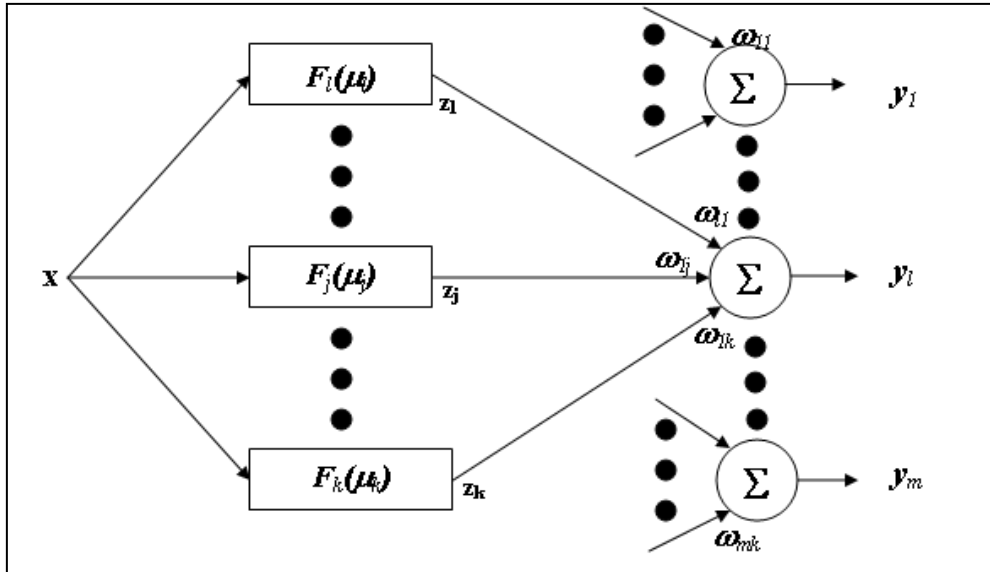


FIGURA 3.6 – ARQUITETURA DAS REDES RBF
FONTE: DIAS (2007)

3.3.2 Processamento das RBF

O processamento consiste em: Unidades escondidas recebem o vetor de entrada x_p , $p = 1, \dots, npad$; ($npad$ é o número de padrões de entrada). Cada unidade na camada escondida produz uma saída z_j considerando a proximidade entre a entrada x_p e um vetor parâmetro n -dimensional μ_j em uma dada vizinhança σ_j de acordo com a expressão matemática (3.8).

$$z_j(x_p) = F_j(x_p, \mu_j, \sigma_j) \quad (3.8)$$

A função F deve fazer com que z_j tenha valor significativo quando o vetor de entrada estiver em sua vizinhança (delimitada pelo campo receptivo), decaindo rapidamente em caso contrário. A saída é um vetor m -dimensional y cujo l -ésimo elemento é dado por (3.9).

$$y_l(x) = \sum_{j=1}^n w_{lj} z_j(x) \quad (3.9)$$

onde w_{lj} é o peso entre a unidade escondida j e a unidade de saída l .

3.3.3 Parâmetros e equações das redes RBF

Redes RBF realizam aproximação de uma função $g(x)$ por superposição de funções de base radial não-ortogonais que têm forma de sino. O grau de precisão pode ser controlado por três parâmetros:

- Número de funções de base usadas;
- Localização e
- Largura do campo receptivo.

As Funções de ativação F das unidades escondidas da rede RBF, mais comuns, são as apresentadas a seguir:

Função de base Gaussiana em (3.10).

$$z_j(x) = e^{-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}} \quad (3.10)$$

onde μ_j é a média do campo receptivo da unidade j , σ_j é o desvio padrão do campo receptivo da unidade j e $\|x - \mu_j\|$ é uma norma Euclidiana.

Função de base logística em (3.11).

$$z_j(x) = 1 + e^{-\frac{\|x - \mu_j\|}{2\sigma_j^2} \theta_j} \quad (3.11)$$

onde θ_j é um “bias” ajustável.

Função multiquadrática inversa em (3.12).

$$z_j(x) = \frac{1}{\left(\|x - \mu_j\|^2 + \sigma_j^2\right)^{\frac{1}{2}}} \quad (3.12)$$

Redes RBF são adequadas para aproximar mapeamentos de valores reais contínuos, ou contínuos por partes $f: R^n \rightarrow R^m$, para n suficientemente pequeno.

3.3.4 Aprendizado em redes RBF

O método de treinamento, assim como nos demais modelos supervisionados, deve reduzir o erro na saída da rede (E) a valores aceitáveis através da adaptação dos parâmetros livres na rede RBF:

- Os centros dos campos receptivos (μ_j);
- As larguras dos campos receptivos (σ_j) e
- Os pesos entre a camada escondida e a camada de saída (w_{ij}).

A aprendizagem pode ser supervisionada, não-supervisionada ou híbrida (que ocorre na maioria dos casos). O treinamento híbrido combina aprendizagem não-supervisionada com supervisionada. A primeira treina a camada escondida, definindo os parâmetros desta camada (localização dos centros e larguras dos campos receptivos). A segunda etapa define os valores dos pesos entre as camadas escondidas e de saída. Nesta segunda fase, os parâmetros definidos na primeira fase não se modificam. Este é o tipo de treinamento mais empregado, pois, em geral, não se sabe que saídas se desejam para a camada escondida.

Resumidamente, tem-se no treinamento não supervisionado a seguinte situação:

1. Determinam-se os valores dos centros por:
 - seleção aleatória;
 - distribuição sobre uma grade regular;
 - técnica de agrupamento (*clustering*);
 - outro algoritmo;
2. Determina-se a largura do campo receptivo através de uma heurística.

Já no Treinamento supervisionado tem-se a seguinte situação:

1. Determinam-se os pesos por um método que resolva o problema de minimização do erro:

- método dos mínimos quadrados;
- método da regra delta;
- matriz pseudo-inversa.

O treinamento não-supervisionado para a camada escondida compreende a determinação dos centros das funções de base radial e das larguras dos campos receptivos. A seguir são apresentados métodos para determinação dos centros das funções de base radial. Os centros da camada escondida podem ser selecionados através das seguintes estratégias:

- Seleção aleatória (Chen, 1991):

Nesta estratégia, os centros são vetores de entrada aleatoriamente selecionados. Esta técnica demanda que os padrões de treinamento representem acuradamente todo o espaço de soluções do problema. Este método é simples e direto, no entanto pode exigir grande número de unidades intermediárias, escolher centros muito próximos uns dos outros que podem acarretar funcionamento inadequado da rede;

- Fixação em grade regular (Bishop, 1996):

Neste caso, os centros são fixados em uma grade regular, cobrindo todo o espaço de entrada. Em geral, este método exige muitas unidades intermediárias para vetores de entrada com dimensão alta (“maldição” da dimensionalidade: crescimento exponencial do número das unidades escondidas);

- Técnicas de agrupamento (Moody e Darken, 1989):

Os centros são definidos por técnicas de agrupamento, entre as quais se destaca o algoritmo de k -médias (a seguir) e mapas auto-organizáveis.

- Algoritmo das k -médias: o algoritmo das k -médias divide os padrões de treinamento em ng grupos, encontrando o ponto central de cada um deles através da expressão (3.13).

$$\mu_j = \frac{1}{nv_j} \sum_{x_p \in S_j} x_p \quad (3.13)$$

onde nv_j é o número de vetores contidos no agrupamento S_j .

Os primeiros centros são inicializados arbitrariamente. Em seguida, os padrões de entrada vão trocando de centro (de acordo com a distância euclidiana) até se chegar a uma situação estável. O número de centros é determinado de acordo com a estratégia de treinamento que pode ser, por exemplo, a validação cruzada.

- Mapas auto-organizáveis: Os mapas auto-organizáveis (SOM, *Self Organizing Maps*) caracterizam-se por agrupar padrões espacialmente próximos que compartilhem micro-características. No início, os centros são aleatoriamente atribuídos. O centro que apresentar maior produto escalar com um dado vetor de entrada adiciona uma versão ponderada deste vetor de entrada ao seu grupo.

As heurísticas para determinação da largura do campo receptivo são apresentadas a seguir. O valor de σ_j pode ser único para todas as unidades ou pode ser diferente para cada unidade escondida. Algumas das principais heurísticas são:

- Utilização da distância euclidiana média entre centros conforme (3.14) (Moody e Darken, 1989):

$$\sigma = \frac{1}{ng} \sum_{j=1}^{ng} \|\mu_j - \mu_{j(mprox)}\| \quad (3.14)$$

onde ng é o número de grupos que serão formados e $\mu_{j(mprox)}$ é o centro com menor distância euclidiana com relação ao centro μ_j . Este método produz um único valor de raio.

- Utilização da distância euclidiana entre centro e vetor de entrada conforme (3.15) (Saha *et. al*, 1990):

$$\sigma_j^2 = \frac{1}{nv} \sum_{x_p \in \Psi_j} \|\mu_j - \mu_p\|^2 \quad (3.15)$$

onde Ψ_j é o conjunto dos nv vetores de entrada com menor distância euclidiana para o centro μ_j .

- Utilização da distância euclidiana entre centros como em (3.16) (Hassoun, 1995):

$$\sigma_j = \alpha \|\mu_j - \mu_{j(mprox)}\| \quad (3.16)$$

onde $\mu_{j(mprox)}$ é o centro com menor distância euclidiana com relação ao centro μ_j e o parâmetro geralmente se situa em $1,0 \leq \alpha \leq 1,5$.

- Utilização da distância euclidiana entre os centros determinados pelo método k -médias como em (3.17).

$$\sigma_j^2 = \frac{1}{na} \sum_{x_p \in S_j} \|\mu_j - x_p\|^2 \quad (3.17)$$

onde S_j é o agrupamento contendo na vetores de entrada.

O treinamento supervisionado para a camada de saída é a etapa que compreende a determinação dos pesos entre a camada escondida e a de saída. A primeira etapa neste processo é o cálculo do erro. O valor do erro é dado em função da resposta dada pela rede comparada com a resposta que se deseja dela. Existem várias maneiras diferentes de se calcular o erro, sendo que algumas delas são apresentadas a seguir:

Soma dos erros quadráticos conforme (3.18) (SSE - *sum of squared error*)

$$SSE = \sum_{i=1}^{npad} \|y_d^{(i)} - y_o^{(i)}\|^2 \quad (3.18)$$

Erro quadrático médio conforme (3.19) (MSE - *mean squared error*)

$$MSE = \frac{1}{npad} \sum_{i=1}^{npad} \|y_d^{(i)} - y_o^{(i)}\|^2 \quad (3.19)$$

Erro relativo médio conforme (3.20) (MRE – *mean relative error*)

$$MRE = \frac{1}{npad} \sum_{i=1}^{npad} \left\| \frac{y_d^{(i)} - y_o^{(i)}}{y_d^{(i)}} \right\|^2 \quad (3.20)$$

Raiz do erro quadrático médio conforme (3.21) (RMSE – *root mean squared error*)

$$RMSE = \sqrt{\frac{1}{npad} \sum_{i=1}^{npad} \|y_d^{(i)} - y_o^{(i)}\|^2} \quad (3.21)$$

Erro Médio Percentual Absoluto conforme (3.22) (MAPE – *mean absolute percentage error*)

$$MAPE = \frac{1}{npad} \sum_{i=1}^{npad} \left\| \frac{y_d^{(i)} - y_o^{(i)}}{y_d^{(i)}} * 100 \right\| \quad (3.22)$$

onde $y_d^{(i)}$ e $y_o^{(i)}$ são o i -ésimo padrão desejado e obtido respectivamente e $npad$ é o número total de padrões.

Depois de calculado o erro, este é minimizado por procedimentos tais como a regra delta, o método dos mínimos quadrados e a matriz pseudo-inversa (os dois últimos, métodos lineares). Neste trabalho utiliza-se o procedimento da matriz pseudo-inversa, o qual será apresentado em detalhes posteriormente.

3.3.5 Estratégias de treinamento

O compromisso entre precisão e generalização deve ser obtido através da aprendizagem. Para tal, duas estratégias de treinamento são, em geral, empregadas: *hold-out* e validação cruzada (*cross-validation*) (HAYKIN, 2001).

Hold-out: Neste procedimento o conjunto de padrões é dividido em três grupos: treinamento, validação e teste. Cada topologia tem, com seus centros, seu desempenho testado com respeito aos três conjuntos.

Validação cruzada: Esta é uma estratégia típica de situações onde todos os padrões devem ser considerados para o treinamento (normalmente, pois eles são poucos). Neste caso, dividem-se os padrões em ng grupos. Seleciona-se aleatoriamente $(ng - 1)$ conjuntos para treinamento e testa-se a rede com aquele conjunto que não foi selecionado. Este processo deve prosseguir até que todos os conjuntos tenham sido usados para testes. A partir daí, calcula-se o erro (E), escolhendo um dos apresentados na seção 3.3.5, que pode ser dado através de (3.23).

$$E = \frac{1}{ng} \sum_{j=1}^{ng} E_i \quad (3.23)$$

3.3.6 Desempenho das redes RBF

As redes RBF têm sido aplicadas com sucesso na aproximação de funções e em problemas de classificação. Em tarefas difíceis de aproximação / interpolação (por exemplo, predição da série caótica de *Mackey-Glass* T instantes de tempo no futuro, $T > 50$), redes RBF que empregam a técnica de agrupamento no posicionamento dos campos receptivos podem alcançar desempenho comparável ao das redes de retropropagação, enquanto requerem tempo de treinamento algumas ordens de grandeza menor (HAYKIN, 2001).

Em tarefas difíceis de classificação, redes RBF empregando um número suficiente de padrões de treinamento e de unidades escondidas podem superar o desempenho de redes retropropagação, obtendo melhores taxas de classificação e menores erros de classificações positivas falsas (HASSOUN, 1995).

As redes RBF têm tempo de treinamento muito menor porque apenas uma pequena fração de unidades escondidas responde a um dado padrão de entrada (pois são unidades localmente sintonizáveis, sensíveis apenas a padrões próximos de seus campos receptivos). Isto permite o uso eficiente de algoritmos auto-organizáveis no ajuste dessas unidades no modo de treinamento, que não envolve a

camada de saída da rede. Por outro lado, todas as unidades de uma rede retropropagação são avaliadas e têm seus pesos ajustados para cada vetor de entrada. Outro fator que contribui para a velocidade de treinamento das redes RBF é o esquema de treinamento separado da camada escondida e da camada de saída.

Quando utilizadas em aproximação de funções, as redes do tipo retropropagação conseguem maior capacidade de generalização (ou extrapolação) do que as RBF, pois ajustam globalmente os padrões de entrada enquanto estas últimas fazem um ajuste local. Pelo mesmo motivo, em problemas de classificação, redes RBF cometem menos erros de falsa classificação positiva do que as redes do tipo retropropagação. Pode-se dizer que, em geral, é melhor o uso de redes do tipo retropropagação quando os padrões de entrada são custosos (ou difíceis de se gerar) e/ou quando a velocidade de recuperação, considerando-se a implementação em máquinas seriais, é crítica. Esse tipo de rede, em geral, é menor, requer menos memória e leva a maiores velocidades de recuperação do que as RBF.

No entanto, se os dados são “baratos” e abundantes, e se é necessário treinamento *on-line* (como no caso de processamento de sinal adaptativo e controle adaptativo, onde os dados são adquiridos em altas taxas e não podem ser salvos), então as redes RBF são superiores (HAYKIN, 2001).

4 PROPOSTAS PARA O TRATAMENTO DOS DADOS E DE MELHORIAS NAS RBF

O sistema de reposição proposto está baseado na qualidade e acurácia da previsão de vendas realizada. Para tal, pretende-se estabelecer uma topologia para as RBF, através da definição dos parâmetros, que consiga generalizar a previsão para todos os tipos de produtos do varejo supermercadista. O objetivo principal é estabelecer uma RBF, na concepção de arquitetura, que possa prever, um a um, toda a gama de produtos. Os testes realizados foram aplicados nos produtos de todas as divisões mercadológicas centralizadas da linha seca, já mencionados.

A variação no comportamento de vendas e no valor total de vendas dos produtos é extremamente alta. Por esse motivo, pode-se aplicar aos mesmos a classificação ABC, onde os produtos A são aqueles 20% que mais contribuem com a venda das lojas, os 30% seguintes são os produtos B, e os 50% finais que, em geral, contribuem pouco com a venda das lojas são classificados como C. Essa Classificação é conhecida como curva 80-20 ou lei de Pareto (BALLOU, 2006), que afirma que cerca de 20% das causas representam aproximadamente 80% dos efeitos encontrados em certa situação.

A grande dificuldade de se encontrar um método eficiente para a previsão é a variação do comportamento dos produtos nestas diferentes classes. Há produtos, que mesmo representando vendas baixas, isto é, produto C, possuem um giro relativamente alto. Também há situações em que produtos de alto valor agregado, que contribuem consideravelmente nas vendas totais, possuem baixo ou baixíssimo giro, vendendo poucas unidades durante um mês inteiro.

Encontrar uma RBF que possa captar essas características é o objetivo, pois uma vez que a previsão seja mais acertada do que o método utilizado por ocasião da pesquisa junto a empresa pode-se melhorar o nível de serviço da empresa e minimizar a ruptura encontrada. A metodologia de previsão escolhida para desenvolvimento foi a RBF devido à qualidade de previsão do método descrito na literatura e a velocidade de processamento computacional. Os resultados obtidos através desta técnica serão comparados com os resultados tidos por ocasião da pesquisa.

A literatura não traz uma definição exata quanto a configuração ideal para a realização de previsão de séries temporais através das RBF, ainda mais séries temporais com poucas ocorrências. As RBF são altamente influenciadas pelos parâmetros escolhidos na definição da sua arquitetura. A quantidade de dados históricos, a topologia da rede, o intervalo escolhido para o padrão de entrada, a janela de tempo de previsão, o algoritmo de agrupamento utilizado na camada intermediária, a definição dos centróides, a dimensão dos campos receptivos de cada centróide, a quantidade de padrões separados para o período de testes da RBF e quais os padrões escolhidos para teste são os elementos da configuração que, se bem definidos, podem influenciar em previsões mais corretas.

Para definir a configuração fazem-se, em geral, processos iterativos que vão modificando, de forma organizada, os parâmetros e escolhas. Faz-se essas alterações, armazenando a(s) melhor(es) solução(ões) parcial(is) obtidas até o momento que a solução seja razoável ou aceitável o suficiente para o tomador de decisão. Nas RBF, o processo de mensurar o desempenho da rede está vinculado ao período de treinamento e teste. Para realizar essas duas fases primeiramente são separados os dados históricos em dois grupos: o conjunto de treinamento, que consiste em apresentar as entradas a RBF e corrigir as saídas sabendo qual é a saída desejada de cada entrada e o conjunto de teste ou validação, que consiste na utilização da rede treinada comparando as suas saídas com as saídas que deveriam ser obtidas.

Para se fazer esta comparação utiliza-se, neste trabalho, a medida do erro RMSE e MAPE. Este índice é obtido em cada uma das configurações obtidas da rede neural a cada iteração, e a configuração que apresentar o menor RMSE é a que mais se encaixa na solução do problema em questão. Este processo também é conhecido como a capacidade de generalização da rede.

Para se definir a configuração da RBF, que será utilizada para se propor melhorias no algoritmo, foram realizados testes computacionais em 9396 séries temporais, sendo cada série com 392 informações (dias seguidos de vendas), agrupadas em 56 semanas seguidas de vendas. Os parâmetros que foram alterados sistematicamente foram: o tratamento de dados ao se agrupar os valores de vendas diários (392) em semanais (56), considerando as características mercadológicas de ruptura e promoção e, ainda, a retirada de *outliers*; a dimensão do padrão de entrada nas RBF; a quantidade de padrões no grupo de treinamento e de teste; o

fator de dimensão dos campos receptivos e os algoritmos de agrupamento para definição dos centróides (neurônios da camada escondida), além da definição da quantidade de centróides.

Uma série temporal consiste de medidas ou observações de um fenômeno que se realiza seqüencialmente em um intervalo de tempo. A série temporal formada pelo histórico de vendas de um produto é a base de dados utilizada para alimentar o método de previsão de vendas. No mercado de varejo existem muitas variáveis que podem influenciar no aumento ou na diminuição de venda de certo produto. Muitas delas são variáveis qualitativas, como, por exemplo, tendência de mercado, preferência do cliente e promoções. Estas variáveis não trazem indicadores precisos “de quando” e “de quanto” podem alterar a quantidade de produtos vendidos e acabam por não retratar a quantidade real de venda do produto em épocas normais de vendas.

As vendas de produtos de varejo podem sofrer interferência de diversas formas, o que é chamado de interferências mercadológicas. Se estiver chovendo ou não, se o concorrente está com o produto em promoção ou não, se o produto foi divulgado em propaganda, seja ela em panfletos e/ou rádio e/ou televisão, se o produto está bem disposto e com visibilidade na gôndola pelo cliente, entre outras características mercadológicas podem justificar o comportamento de vendas de um produto.

A sazonalidade dos produtos é uma característica identificada facilmente pela análise da série temporal, porém de difícil reprodução no momento de prever o comportamento das vendas. Além disso, promoções exclusivas de uma loja ou acontecimentos inesperados nas redondezas da loja podem também influenciar o comportamento de vendas de um produto. Com isso, esses fatores devem ser identificados e retirados da série original, suavizando os dados e obtendo o comportamento real de venda do produto.

Neste trabalho decidiu-se por tratar dois tipos de interferência, isto é, fatores que podem alterar o comportamento “considerado normal” do produto. A disponibilidade do produto, isto é, se aconteceu venda ou não do produto devido a ruptura, e o fato do produto estar em algum tipo de promoção, com seu preço alterado para baixo, fazendo aumentar a venda do produto acima do “normal”.

4.1 PROPOSTAS PARA TRATAMENTO DOS DADOS

Neste trabalho foram utilizados dois tratamentos de dados e, também, as informações originais (ou brutas) de vendas sem nenhum tipo de consideração ou suavização para criar a série temporal formada pelas 56 semanas seguidas de venda do produto.

4.1.1 Primeiro tratamento

O primeiro tratamento de dados é a identificação de “outliers” através da técnica estatística *box-plot* de representação gráfica envolvendo quartis. Identifica-se, dentre os 392 dados de vendas diárias, de certo produto de certa loja, quais ocorrências são vendas em promoção ou vendas zeradas devido a rupturas. Do conjunto de dados não identificados faz-se os cálculos referentes à técnica *box plot*, como apresentado na Figura 4.1 a seguir:

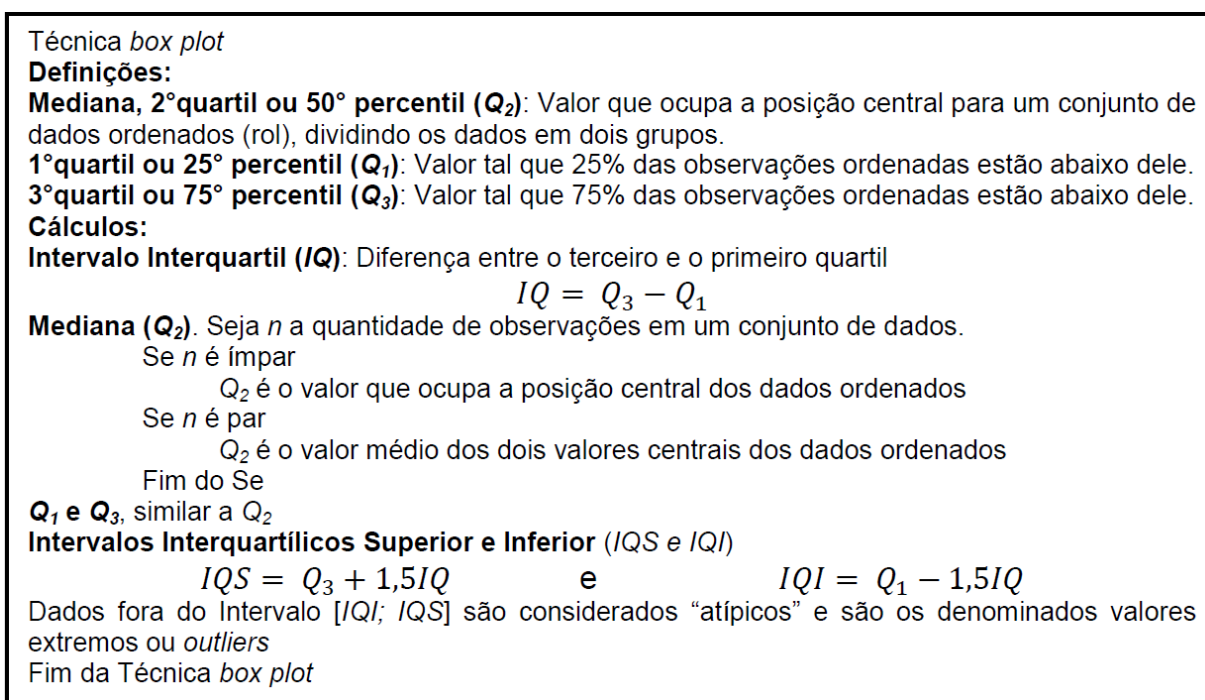


FIGURA 4.1 – REPRESENTAÇÃO ESQUEMÁTICA DA TÉCNICA *BOX PLOT*
 FONTE: O AUTOR (2011)

O 1º e o 3º quartis são calculados como se fossem a mediana dos dois conjuntos separados no cálculo da mediana citada, com as mesmas considerações sobre a quantidade de observações em cada conjunto. Se o conjunto de dados for ímpar, considera-se a mediana como parte de cada um dos conjuntos encontrados. Se o conjunto de dados for par, a mediana não é incluída em nenhum desses conjuntos.

De maneira informal, consideram-se o 1º e o 3º quartis como valores que dividem o conjunto de dados nas metades de cada metade. Considera-se um conjunto de dados “bem comportados”, quando a maior parte das observações está dentro do Intervalo $[IQI; IQS]$, sendo que dados fora desse intervalo são considerados “atípicos”, pois apresentariam um padrão distinto do esperado para a maior parte das unidades experimentais. Esses pontos fora do intervalo anteriormente definido são os denominados valores extremos ou *outliers*.

Com todos esses elementos, tem-se então a possibilidade de criar uma representação gráfica que permite visualizar diversos aspectos da distribuição dos dados, chamada de *box plot*, conforme Figura 4.2.




FIGURA 4.2 – EXEMPLO DA REPRESENTAÇÃO GRÁFICA DA METODOLOGIA *BOX PLOT*
 FONTE: O AUTOR (2011).

O primeiro tratamento proposto consiste em, uma vez encontrado o intervalo $[IQI; IQS]$, retornar a série de dados originais e substituir os valores fora desse intervalo por um valor gerado aleatoriamente dentro do intervalo $[IQI; IQS]$. Pretende-se assim, gerar uma série de dados “mais bem comportada”, para então agrupar os valores de vendas diários, a cada 7 dias, em semanais, respeitando

sempre a ordem cronológica das informações e obtendo os 56 valores de vendas semanais que “alimentarão” o método de previsão.

4.1.2 Segundo tratamento

O segundo tratamento, proposto neste trabalho, é o seguinte: dos 392 dados originais, como mostrado na Figura 4.3 a seguir, foram retirados os valores das quantidades vendidas obtidas nos dias em que o produto (no exemplo, pêssego de 450 g) esteve em promoção e, dos dados restantes, colocados em rol (ordem crescente), foram retirados 5% dos dados do extremo inferior e 5% dos dados do extremo superior, minimizando a possibilidade de ruído branco (baseada na técnica *box plot*). O valor de 5% foi escolhido empiricamente baseado no fato de que em todos os 9396 testes realizados a quantidade de valores *outliers* referentes aos dados sem promoção foi menor que 3% dos valores considerados sem interferências mercadológicas. Porém a geração de valores aleatórios no segundo tratamento é diferente do primeiro tratamento.




FIGURA 4.3 – DADOS ORIGINAIS PRODUTO PÊSSEGO 450G - 392 OCORRÊNCIAS
 FONTE: O AUTOR (2009).

Obtendo-se os valores considerados com insignificantes influências mercadológicas ou dados de “comportamento normal de venda”, calcula-se a média e o desvio padrão destes dados. Geram-se, aleatoriamente, dados dentro do intervalo centrado na média e com raio igual a um desvio padrão, que irão substituir os dados que foram retirados. Para este tratamento de dados deve-se salientar, novamente, que a posição da informação dentro da série temporal é imprescindível

para a qualidade da previsão pretendida. Da mesma forma, agrupam-se os valores de vendas a cada 7 dias e encontram-se os 56 valores de vendas semanais.

Os 56 valores semanais de vendas assim tratados (após a aplicação dos tratamentos) serão doravante denominados de **dados suavizados**, para ambos os tratamentos.

No caso em que o limite inferior $/Q/$ do primeiro tratamento ou subtração da média por um desvio padrão do segundo tratamento for negativa, utiliza-se o limitante inferior da geração aleatória por zero, não permitindo gerar valores de vendas negativos.

Na Figura 4.4, a seguir, é apresentado um exemplo de dados do produto “Farinha 1 Kg”, onde é comparada a série temporal original, sem nenhum tipo de tratamento e a série temporal após o segundo tratamento, utilizada para alimentar futuramente o algoritmo de previsão.




FIGURA 4.4 – EXEMPLO DE SUAUIZAÇÃO DOS DADOS
FONTE: O AUTOR (2009).

4.2 DEFINIÇÃO DOS PARÂMETROS DA RBF

4.2.1 Parâmetro: Padrões de entrada

A série temporal formada pelos 56 valores encontrados deve ser informada para o algoritmo de previsão RBF. O “formato” para apresentação dos dados para o

algoritmo de RNA escolhido é o que se chama de dimensão do padrão de entrada ou a definição do número de ocorrências no vetor de entrada. Este é um fator extremamente relevante para a configuração da RBF quando está utilizando-a para a previsão de séries temporais.

A quantidade de ocorrências no vetor de entrada corresponde ao número de atrasos unitários no tempo que utilizaremos sobre a série temporal em questão podendo ser representado por: $N, N-1, N-2, \dots, N-K$, onde N são as ocorrências sobre a série temporal e K o número do maior atraso unitário que será considerado. O atraso pode ser em um intervalo de uma unidade ou mais, porém em um tamanho fixo que pode ser, por exemplo, um intervalo de tamanho 2, atrasando 4 vezes em relação a certo valor, obtendo 5 ocorrências: $N, N-2, N-4, N-6$ e $N-8$.

Neste trabalho, devido a característica do problema, foi definido um intervalo de uma unidade e testados vetores com 3, 4 e 5 ocorrências, equivalentes a 3 semanas, 4 semanas (ou, aproximadamente, 1 mês) e 5 semanas de vendas. A formação dos vetores de entrada da RBF é realizada selecionando as ocorrências de uma forma organizada para compor este vetor, formando o que se conhece como janela do tempo. Os valores que compõem a janela do tempo serão considerados pela RBF para efetuar o treinamento da mesma, onde o seu objetivo é calibrar os pesos internos para que seja alcançado o valor da ocorrência $N+1$, ou seja, consideraremos K períodos passados ao longo da serie temporal, para prever um período a frente.

Para padrões de entrada com 3 ocorrências obteve-se 53 padrões de entrada, para padrões formados com 4 ocorrências obteve-se 52 padrões de entrada e, finalmente, para padrões com 5 ocorrências seguidas obteve-se 51 padrões de entrada. Por exemplo, o primeiro padrão de entrada da RBF, para padrão com 4 ocorrências, são os valores das semanas 1, 2, 3 e 4, nesta ordem, e a saída utilizada é a semana 5. O segundo padrão de entrada é formado pelos valores das semanas 2, 3, 4 e 5 (nesta ordem) e a saída correspondente é a semana 6, e assim por diante até o último padrão que possui como saída o valor da semana 56.

De acordo com a série temporal o número de atrasos pode variar melhorando a previsão, já que a mesma pode conter sazonalidades em algum período ao longo do ano; a quantidade de ocorrência no vetor de entrada pode auxiliar a RBF a identificar esses períodos para uma maior acuracidade em sua previsão.

Este é a justificativa para se de testar 3 tamanhos de vetores na entrada de dados, sendo que a escolha da quantidade de atrasos foi devida a característica mercadológica de ser próxima de um mês de venda, visando captar uma possível relação entre as semanas de cada mês ou pelo menos próximo de um mês, quando esse ciclo provavelmente volta a se repetir. Depois do treinamento da RBF, é utilizada a mesma quantidade de atrasos unitários, para fazer a validação / testes e as previsões.

4.2.2 Parâmetro número de padrões para teste

Na literatura sobre as RNA é comum encontrar uma porcentagem que pode variar entre 10% a 40% de padrões de entrada para realização dos testes e que, ainda, essa porcentagem não seja necessariamente a última parte do conjunto de dados (SILVA, *et. al*, 2010). Assim, em uma série temporal, onde a sequência das informações é um fator relevante, decidir qual será a quantidade de padrões que será utilizado para testes e qual será a posição dessas quantidades é uma tarefa que pode influenciar diretamente na qualidade de previsão desejada.

Nos primeiros testes computacionais realizados nas 9396 séries temporais, foram testados 3 porcentagens de padrões para testes: 30%, 20% e 8% dos padrões. A escolha de 8% (e não de 10%) foi devida ao fato que 8% representa 4 padrões, isto é, aproximadamente dois meses de dados, o que, analisando o contexto da aplicação, pode ter mais significado prático no modelo. Em todos esses primeiros testes, essas porcentagens de padrões foram retiradas do período de treinamento da última parte dos dados, isto é, por exemplo, para o teste com um padrão formado com 3 ocorrências (53 padrões no total) e 20% de padrões separados para teste (11 padrões), foram treinadas as redes com os 42 primeiros padrões de entrada e os últimos 11 padrões para o período de teste.

Uma vez definida essa porcentagem para o período de teste e a localização dos padrões que formarão o conjunto de teste, pode-se definir as matrizes que alimentarão a RBF. Neste trabalho definiu-se da seguinte forma: Matriz $P(k \times e)$, com k = tamanho de ocorrências na formação de um padrão; e = quantidade de padrões do conjunto de treinamento, é a matriz que contém o conjunto de dados para o

treinamento; $P1(k \times t)$, com t = quantidade de padrões do conjunto de testes, é a matriz que contém o conjunto de dados para o teste; $T(1 \times e)$ é a matriz que contém o conjunto de dados referentes às “respostas alvo” dos padrões de entrada colocados nas colunas de P para o período de treinamento; $T1(1 \times t)$ é a matriz que contém o conjunto de dados referentes às “respostas alvo” dos padrões de entrada colocados nas colunas de P para o período de testes. A Figura 4.5 ilustra a formação das matrizes citadas.

Matriz P de Treinamento				
P =	Ocorrência 1	Ocorrência 2		Ocorrência 42
	Ocorrência 2	Ocorrência 3	...	Ocorrência 43
	Ocorrência 3	Ocorrência 4		Ocorrência 44
Matriz T de alvo para os padrões de Treinamento				
T =	Ocorrência 4	Ocorrência 5	...	Ocorrência 45
Matriz P1 de Teste				
P1 =	Ocorrência 43	Ocorrência 44		Ocorrência 53
	Ocorrência 44	Ocorrência 45	...	Ocorrência 54
	Ocorrência 45	Ocorrência 46		Ocorrência 55
Matriz T1 de alvo para os padrões de Teste				
T1 =	Ocorrência 46	Ocorrência 47	...	Ocorrência 56

FIGURA 4.5 – FORMAÇÃO DAS MATRIZES PARA AS RBF
FONTE: O AUTOR (2011).

4.2.3 Parâmetro: Fator dimensão dos campos receptivos

O parâmetro fator dimensão dos campos receptivos relaciona-se aos raios dos campos receptivos das unidades escondidas da rede neural, e é um dos mais importantes parâmetros para o treinamento das Redes Neurais com base radial, pois o mesmo determina o ajuste da linearidade em torno da série temporal.

Os neurônios pertencentes a camada intermediária da RBF são constituídos de funções de ativação do tipo base radiais, sendo que a função gaussiana é a empregada neste trabalho. A função gaussiana, já apresentada em (3.10), é remodelada da seguinte forma em (4.1):

$$z_j(x) = e^{-\frac{\|x-\mu_j\|^2}{2\sigma_j^2}} \quad (4.1)$$

onde μ_j define o centro da função Gaussiana e σ_j^2 denota a sua variância (em que σ equivale ao desvio padrão), o qual indica o quão disperso está o potencial de ativação x em relação ao seu centro (SILVA, *et al.*, 2010). Quanto maior for o valor da variância, mais alargada será a sua base e, consequentemente, mais padrões estarão classificados como sendo destinados a esse centro, fazendo com que a RBF retorne uma previsão similar em relação aos padrões classificados dentro do agrupamento deste centróide, claro, de acordo com seus componentes.

Desta forma, os parâmetros livres a serem ajustados seriam então a quantidade dos centros, ou centróides, e a posição de cada um deles, além da variância ou raio do campo receptivo. Se o valor atribuído a este parâmetro for extremamente pequeno pode ocorrer uma distorção na generalização da rede neural, pois os agrupamentos serão de padrões muito próximos. Se um padrão for apresentado a RBF, esta pode não reconhecer seu agrupamento mais correto e, além disso, a exigência de número de centróides ficará muito grande, pois a atuação de cada um é pequena. Assim, além de perder poder de generalização, exige-se mais capacidade computacional, uma vez que necessitará inverter uma matriz de ordem maior. Se o valor atribuído a este parâmetro for extremamente grande, a necessidade de centróides diminui, mas a RBF não consegue identificar as possíveis características numéricas de forma a resultar em uma previsão mais coerente.

Encontrar o número de centróides e o raio de atuação de cada um deles é uma tarefa realizada através de testes computacionais. Na literatura, não é incomum encontrar trabalhos que visam somente testes de quantidades de centróides e tamanho dos campos receptivos, sendo este tema alvo de diferentes pesquisas (MENG, *et. al*, 2009) (UYSAL, 2006) (ZHAO, *et. al*, 2004). Neste trabalho, foram realizados testes de 1 até e centróides (e = núm. de padrões do conjunto de treinamento) em todas 9396 séries temporais para cada variação realizada nos primeiros testes. Em cada variação testam-se 3 valores, chamado de *BSpread*, escolhidos para substituir na função Gaussiana a seguinte expressão $\frac{1}{2\sigma_j^2}$.

Sendo que a variável *BSpread* é calculada da seguinte maneira alternativa ao cálculo da variância, dada pela relação (4.2).

$$BSpread^2 = \frac{\sqrt{-\ln 0.5}}{Spread} = \frac{1}{2\sigma_j^2} \quad (4.2)$$

Assim, a função gaussiana utilizada na ativação, é dada por (4.3).

$$z_j(x) = e^{-\|x-\mu_j\|^2 * Bspread^2} \quad (4.3)$$

Com essa alteração, os valores de *Spread* nos testes realizados foram: 0,5, resultando em um *BSpread* de aproximadamente 1,67, diminuindo a atração do padrão para o campo receptivo do centróide *j* após a aplicação da função de ativação (valor menos significativo tendendo a zero); 0,83, resultando em um *BSpread* de aproximadamente 1, mantendo a atração do padrão para o campo receptivo do centróide *j* após a aplicação da função de ativação e; 1,5, resultado em um *BSpread* de aproximadamente 0,56, aumentando a atração do padrão para o campo receptivo do centróide *j* após a aplicação da função de ativação (valor mais significativo tendendo a 1). Em tal condição, o neurônio *x* produzirá respostas similares para todos aqueles padrões que estejam a uma mesma distância radial do centróide *j* da Gaussiana.

4.2.4 Testes e definições dos parâmetros

Apresentados todos os parâmetros do modelo da RBF, tem-se: 3 tipos de pré-tratamento dos dados (dados brutos, retiradas dos *outliers*, e suavização), 3 tamanhos de padrões de entrada (com 3, 4 ou 5 ocorrências), 3 porcentagens de padrões para separação em conjunto de treinamento e teste (30%, 20% e 8%), 3 fatores *Spread* para aplicação na função de ativação Gaussiana, resultando em 81 configurações, e ainda, considerando que em cada uma destas combinações testou-se de 1 até *t* centróides, com *t* variando de acordo com a porcentagem de padrões

no conjunto de teste, tem-se aproximadamente em 3042 combinações de parâmetros aplicadas nas 9396 diferentes séries temporais, compostas por 116 produtos diferentes acompanhados por 81 semanas seguidas, perfazendo aproximadamente 31965162 testes computacionais, apresentados em resumo na Tabela 4.1.

TABELA 4.1 – QUANTIDADE DE PRODUTOS POR DIVISÃO MERCADOLÓGICA E CLASSIFICAÇÃO ABC

Divisão Mercadológica	Classificação					Total geral
	A	B	CA	CB	CC	
Açougue	10	7	2			19
Bazar		1		1		2
Bebidas	5	1				6
Eletro	10			4	10	24
Higiene	4					4
Limpeza	9	4				13
Mercearia	25	10	1			36
Perecíveis	3	6				9
<i>Pet Shop</i>		1	2			3
Total geral	66	30	5	5	10	116

FONTE: O AUTOR (2011).

Com esses testes pretendeu-se delimitar os parâmetros que mais resultavam em previsões mais acuradas, isto é, qual, das 81 configurações, tinha a capacidade de, na média, se aproximar mais do valor da ocorrência da semana 57 em cada uma das 9396 séries temporais. Essa é a primeira tentativa de chegar a uma configuração e arquitetura da RBF que poderia generalizar a previsão para qualquer um dos produtos sem ter que ficar realizando testes computacionais para cada série temporal gerada, isto é, para cada produto.

Para cada uma das 9396 séries temporais, para cada configuração de rede, foram contabilizadas quantas séries ficaram com o erro MAPE entre os intervalos determinados como segue na Tabela 4.2. Percebe-se nesses dados que cerca de 17,1% dos produtos são considerados irregulares, isto é, produtos cuja previsão são maiores que o dobro do valor a ser previsto ou zero. Estes produtos irregulares são considerados de difícil previsibilidade e, segundo Ballou (2006), deve-se dar atenção especial para este tipo de produto.

Os valores da Tabela 4.2 foram encontrados contabilizando-se, para cada série temporal, o menor erro no período de teste dentre as 81 configurações

propostas inicialmente. Um fator que ainda não está sendo considerado é a quantidade de centróides nestes testes. Para determinar os valores da Tabela 4.2 considerou-se para cada faixa a média dos valores encontrados para cada centróide de cada configuração. Assim estes valores são apenas referências para se compreender o nível de acuracidade que se tem nos testes ao se aplicar a RBF com estas configurações.

TABELA 4.2 – RESULTADOS DOS PRIMEIROS TESTES REALIZADOS

RMSE no período de Teste, no intervalo	Quantidade	%	% acumulada
0% - 5%	759	8,08%	8,08%
5% - 15%	1272	13,54%	21,62%
15% - 25%	1196	12,73%	34,34%
25% - 35%	1051	11,19%	45,53%
35% - 45%	909	9,67%	55,20%
45% - 55%	718	7,64%	62,85%
55% - 65%	545	5,80%	68,65%
65% - 75%	466	4,96%	73,61%
75% - 85%	412	4,38%	77,99%
85% - 95%	465	4,95%	82,94%
>95%	1603	17,06%	100,00%
Total	9396	100,00%	

FONTE: O AUTOR (2011).

Nesta Tabela 4.2, tem-se na 1ª coluna os intervalos do RMSE do período de teste criados para contagem de séries temporais, na 2ª coluna tem-se a quantidade de séries temporais em cada intervalo de erro no período de teste. Na 3ª e 4ª colunas têm-se o percentual de séries temporais em cada faixa e o percentual acumulado.

Assim, na Figura 4.6 tem-se o gráfico sobreposto da quantidade de séries temporais em cada intervalo (gráfico em colunas), sendo o eixo vertical esquerdo sua referência e o percentual acumulado de quantidade de séries temporais em cada intervalo (gráfico em linhas com marcadores), sendo o eixo vertical direito sua referência. Percebe-se que, por exemplo, para 55% das séries temporais o menor erro de teste obtido por série temporal será de até 45% da meta desejada. Fica difícil dizer se estes valores são considerados bons ou ruins em termos de previsão, pois não se sabe se a previsão para todo o conjunto de produtos também se encontrará nestes patamares.




FIGURA 4.6 – DISTRIBUIÇÃO DOS ERROS NOS PRIMEIROS TESTES
 FONTE: O AUTOR (2011).

A definição dos parâmetros foi dada pela média de séries temporais classificadas até certo erro acumulado, avaliando o comportamento e diferença entre essa quantidade.

Os tratamentos de dados utilizados neste trabalho foram avaliados da seguinte forma: calculou-se a quantidade proporcional as 9396 séries temporais, dentre todos os testes realizados, com cada um dos 3 tipos de tratamento de dados, conforme apresentados na Tabela 4.3 e na Figura 4.7.

TABELA 4.3 – ERROS OBTIDOS COMPARANDO OS TRATAMENTOS DE DADOS

RMSE de teste	Brutos	Box-Plot	Proposto
RMSE até 5	755,2	774,8	767,2
RMSE até 15	1991,1	2049,6	2131,6
RMSE até 25	3124,5	3249,2	3426,8
RMSE até 35	4125,5	4334,5	4518,9
RMSE até 45	4969,0	5248,6	5501,5
RMSE até 55	5652,9	5973,3	6261,9
RMSE até 65	6191,4	6525,2	6817,7
RMSE até 75	6659,6	7014,7	7260,5
RMSE até 85	7071,0	7465,2	7637,3
RMSE até 95	7480,7	7976,8	8081,6
Total	9396	9396	9396

FONTE: O AUTOR (2011).

Na Tabela 4.3, tem-se na 1ª coluna os intervalos acumulados criados para o cálculo proporcional de séries temporais de acordo com os erros obtidos no período de teste, na 2ª coluna tem-se a quantidade proporcional de séries temporais em cada intervalo de erro acumulado no período de teste para os dados brutos. Na 3ª e

4ª colunas têm-se as mesmas contas, porém para o tratamento de retiradas de *outliers*, pela técnica *box plot*, e pela suavização proposta neste trabalho, respectivamente. Na Figura 4.7 pode-se perceber que o tratamento proposto, a suavização de dados, “cresce” ligeiramente mais rápido que os outros tratamentos de dados testados. Isto significa que na suavização há uma maior quantidade de séries temporais com menores erros no período de treino, proporcionalmente aos outros tratamentos testados.




FIGURA 4.7 – ERRO ACUMULADO NO TRATAMENTO DE DADOS
FONTE: O AUTOR (2011).

Assim decidiu-se utilizar a suavização de dados proposta para a continuação dos testes e busca da melhor configuração generalista.

Outro fator que teve uma tendência maior de acerto para a previsão ou menor erro no período de testes da RBF foi a porcentagem de padrões para teste. A porcentagem de 30% do número total de padrões foi a que apresentou melhores resultados. Entretanto, devido a posição dessa porcentagem, os últimos 30%, pode-se entender que ao se selecionar aleatoriamente uma porcentagem de padrões para teste a previsão fica melhor, como se pode observar na Figura 4.8 e na Tabela 4.4.

Selecionando para teste os últimos padrões e o treinamento sendo feito até aquele padrão anterior ao primeiro padrão de teste e, portanto, influenciando na aprendizagem da RBF, o teste será baseado nas informações imediatamente anteriores ao período de treinamento, e assim obtendo melhor solução, pois como a quantidade de padrões é maior, o erro é suavizado. No caso de porcentagem menor de teste, uma diferença grande entre o valor desejado e o obtido, leva a erros maiores, pois representam pesos maiores no cálculo do erro.

Escolheu-se, então, uma porcentagem de 8% de teste, porém selecionando aleatoriamente os padrões dentre todos os padrões, menos os 4 últimos padrões gerados que significam, com dimensão de padrão 4, os dois últimos meses de vendas. Assim, pretende-se fazer com que o treinamento influencie na aprendizagem da RBF para um melhor acerto na previsão e não no teste.

TABELA 4.4 – ERROS OBTIDOS PARA PORCENTAGEM DE PADRÕES PARA TESTES

RMSE de teste	8%	20%	30%
RMSE até 5	761,6	755,2	780,5
RMSE até 15	2030,0	2036,5	2105,7
RMSE até 25	3217,6	3230,8	3352,1
RMSE até 35	4252,5	4300,7	4425,8
RMSE até 45	5159,6	5199,1	5360,4
RMSE até 55	5860,8	5930,5	6096,7
RMSE até 65	6385,0	6479,2	6670,1
RMSE até 75	6838,9	6973,9	7121,9
RMSE até 85	7248,0	7406,1	7519,4
RMSE até 95	7804,4	7851,8	7882,8
Total	9396	9396	9396

FONTE: O AUTOR (2011)

A Tabela 4.4 é similar a Tabela 4.3, alterando somente o significado das colunas 2, 3 e 4, que são os 3 testes de porcentagem de padrões para o período de testes, 8%, 20% e 30%, respectivamente. A Figura 4.8 é similar a Figura 4.7 é percebe-se um maior crescimento para a porcentagem de 30% de padrões de entrada para o período de testes, conforme comentado anteriormente.




FIGURA 4.8 – ERRO ACUMULADO NA PORCENTAGEM DE PADRÕES PARA TESTE
FONTE: O AUTOR (2011).

A dimensão de Padrões e o Fator *Spread* não tiveram uma variação significativa entre as opções, respectivamente apresentados na Tabela 4.5 e na Tabela 4.6, as quais são similares às recém apresentadas. Percebe-se uma tendência para a escolha de 4 ocorrências para a geração de um padrão de entrada da RBF e um Fator *Spread* entre 1 e 1,5.

O fator *Spread* pode não ter sido alterado devido ao fato que todos os testes foram realizados com o mesmo algoritmo de agrupamento, e então a formação de clusters não tinha grande variação. Com isso, escolheu-se que o padrão de entrada será formado por um vetor de 4 ocorrências seguidas (aprox. 1 mês de vendas) e o fator *Spread* será alterado de acordo com o algoritmo de agrupamento utilizado.

TABELA 4.5 – ERROS OBTIDOS PARA A DIMENSÃO DO PADRÃO DE ENTRADA

RMSE de teste	3	4	5
RMSE até 5	768,0	777,0	752,2
RMSE até 15	2045,3	2076,7	2050,2
RMSE até 25	3256,1	3294,5	3249,8
RMSE até 35	4322,4	4356,2	4300,3
RMSE até 45	5229,1	5263,2	5226,7
RMSE até 55	5958,4	5977,5	5952,1
RMSE até 65	6503,7	6525,9	6504,7
RMSE até 75	6966,4	6999,4	6969,0
RMSE até 85	7367,9	7424,2	7381,4
RMSE até 95	7805,2	7886,1	7847,8
Total	9396	9396	9396

FONTE: O AUTOR (2011).

TABELA 4.6 – ERROS OBTIDOS PARA O FATOR *SPREAD*

RMSE de teste	0,5	1	1,5
RMSE até 5	765,4	765,3	766,5
RMSE até 15	2051,9	2058,0	2062,3
RMSE até 25	3259,2	3268,4	3272,9
RMSE até 35	4324,9	4324,9	4329,2
RMSE até 45	5238,3	5239,3	5241,5
RMSE até 55	5959,3	5962,7	5966,0
RMSE até 65	6511,3	6509,4	6513,6
RMSE até 75	6981,6	6974,8	6978,3
RMSE até 85	7395,2	7386,6	7391,7
RMSE até 95	7858,7	7837,2	7843,1
Total	9396	9396	9396

FONTE: O AUTOR (2011).

Desta forma, os primeiros parâmetros da RBF foram selecionados e o algoritmo de agrupamento passa ser então o foco do trabalho, pois de acordo com a literatura, quanto melhor o agrupamento realizado na etapa de treinamento da RBF,

melhor será o poder de generalização e previsão da mesma. Portanto os parâmetros definidos para a RBF são: o tratamento de dados utilizado é a suavização proposta; a dimensão do padrão terá 4 ocorrências seguidas; 8% (isto é, 4 padrões) de padrões separados para o conjunto de teste da RBF; e o fator *Spread* igual a 1.

4.3 PROPOSTAS DE ALTERAÇÕES NAS RBF RELACIONADAS COM A ETAPA DE AGRUPAMENTOS DE PADRÕES

A RBF utilizada nesta primeira seção de testes é a implementada no *software* matemático MATLAB®, sendo o agrupamento definido pela menor distância entre um padrão de entrada e o centróide mais próximo do mesmo. Os centróides, por sua vez, são escolhidos entre os próprios padrões de entrada. Entretanto, não foi utilizado o *software* MATLAB®, o algoritmo foi reprogramado em Linguagem *Visual Basic* 6, cujo pseudocódigo da RBF é apresentado a seguir.

Os elementos necessários para a entrada no algoritmo são as matrizes $P(k \times e)$, $P1(k \times t)$, $T(1 \times e)$, $T1(1 \times t)$ e o Fator *Spread* (b). Inicialmente, aplica-se a função de Base Radial como apresentado a seguir, na Figura 4.9, no Módulo *RadBas*.

```

Módulo RadBas
Entradas: Matriz  $P(k \times e)$ ,  $W1(k \times c)$ ,  $b$ , onde
 $W1(k \times c) = \begin{cases} P, \text{ isto é, } c = 0, \text{ para a escolha do 1º centróide (gera } G) \\ \text{Col. de } P \text{ escolhidas como Centróides para iterações de } c = 1, \dots, e. (\text{gera } A1) \end{cases}$ 
    Calcular Matriz de Distâncias ( $e \times e - c$ ):  $Dist(i, j) = \sqrt{\sum_{m=1}^k (P(m, i) - W1(m, j))^2}$ , onde  $i = 1, \dots, e; j = 1, \dots, e - c$ .
    Calcular Matriz  $G(e \times e - c)$ :  $G(i, j) = e^{-Dist(i, j)^2 \cdot b^2}$ 
Saída: Matriz  $G(e \times e - c)$ 
Fim do Módulo RadBas

```

FIGURA 4.9 – MÓDULO RADBAS DO MATLAB PARA O CÁLCULO DA FUNÇÃO DE ATIVAÇÃO
FONTE: O AUTOR (2011).

A seguir calcula-se a matriz E , que servirá de apoio à escolha do primeiro centróide. É neste procedimento que se calcula os centróides, o qual está baseado em encontrar o padrão (cada padrão pode ser entendido como um ponto com 4 elementos ou ocorrências, como apresentado anteriormente), entre os que não são centróides na iteração do momento (candidatos). A escolha dá-se pela relação entre

uma ponderação dos pontos candidatos e a saída gerada, ponto a ponto, e a soma de todos os pontos como sendo centróides, onde esta relação seja a máxima encontrada. Isto é, escolhe-se como centróide o padrão que consegue generalizar mais os valores alvos de todos os padrões candidatos na iteração do momento, chegando a um menor erro individual de agrupamento (Matriz $E2$, somatório das distâncias ao quadrado após a ativação da função Gaussiana para cada padrão) em relação à soma considerando todos os padrões como centróides (Matriz $E3$). Para obtenção dos centróides aplica-se a procedimento apresentado no Módulo *CalcErro*, apresentado na Figura 4.10 a seguir.

```

Módulo CalcErro
Entradas: Matriz  $G(e \times e - c)$  e  $T(1 \times e)$ 
    Se  $c > 0$  então atualize  $G$  ( $Pick^*$  = coluna  $Pick$  encontrada na última iteração realizada)
        Atualize  $Wj(e, 1)$ :  $Wj(j, 1) = G(j, Pick^*)$ 
        Calcule  $Aux1(1, e - c)$ :  $Aux1 = Wj' * G$ 
        Calcule  $Aux2(1, 1)$ :  $Aux2 = Wj' * Wj$ 
        Calcule  $A(1, e - c)$ :  $A(1, j) = \begin{cases} \frac{Aux1(1, j)}{Aux2(1, 1)}, \forall j = 1, \dots, e - c, se\ Aux2(1, 1) \neq 0 \\ 0, c. c. \end{cases}$ 
        Calcule  $Aux(e, e - c)$ :  $Aux = Wj * A$ 
        Atualize  $G(e \times e - c)$ :  $G = G - Aux$ 
    Fim do Se
    Calcular Matriz  $GG(1 \times e - c)$ :  $GG(1, j) = \sum_{i=1}^e G(i, j)^2, \forall j = 1, \dots, e - c$ 
    Calcular Matriz  $DD(1 \times 1)$ :  $DD(1, 1) = \sum_{i=1}^e D(i, 1)^2, onde\ D = T'$ 
    Calcular  $E1(e - c \times 1)$ :  $E1 = G' * D$ 
    Calcular  $E2(1 \times e - c)$ :  $E2(1, j) = E1(j, 1)^2, \forall j = 1, \dots, e$ 
    Calcular  $E3(1 \times e - c)$ :  $E3 = DD * GG'$ 
    Calcular  $E(1 \times e - c)$ :  $E(i, j) = \frac{E2(i, j)}{E3(i, j)}$ 
    Encontrar  $Pick = j^*$ , onde  $j^* = j, tal\ que\ Max\{E(1, j), \forall j = 1.., e\}$ 
    Retirar a coluna  $Pick$  das matrizes  $G, E, GG'$ 
Saída: Matriz  $E(1 \times e)$ ,  $Pick$ 
Fim Módulo CalcErro

```

FIGURA 4.10 – MÓDULO *CALCERRO* DO MATLAB PARA OBTENÇÃO DOS CENTRÓIDES
FONTE: O AUTOR (2011).

O valor de *Pick* representa qual a coluna da matriz P , isto é, qual o padrão, que será o próximo centróide escolhido para a camada escondida da RBF. Na primeira iteração, a matriz $W1$ torna-se, a partir deste momento do algoritmo, a matriz de centróides e terá apenas um centróide (um padrão) ficando com dimensão $k \times 1$. Em seguida aplica-se novamente a função *RadBas* com a nova matriz $W1$, obtendo os pesos das conexões entre a camada de entrada e a camada oculta da RBF com um centróide, sendo que a saída deste módulo é renomeada de Matriz $A1$ (antiga G).

A seguir calculam-se os pesos entre a camada escondida e a camada de saída da RBF, para que se possa estimar o erro de teste da RBF com um centróide ($c = 1$). A cada iteração completada, utiliza-se este mesmo procedimento para a obtenção do segundo, terceiro, etc. centróide de forma cumulativa, isto é, o segundo centróide é a escolha do padrão que, uma vez definido o primeiro centróide na iteração anterior, minimize o erro de generalização dos alvos, em relação aos padrões não centróides até o momento.

Assim, a cada iteração agrega-se a camada escondida um centróide a mais, até o máximo de e centróides. Para cada iteração, definem-se os pesos lineares entre a camada escondida e a camada de saída, fazendo o ajuste de treinamento e utilizando estes mesmo pesos para a realização da etapa de teste. Assim para cada iteração, ou seja, para cada quantidade diferente de centróides tem-se um erro de ajuste da série e um erro de teste, sendo feito para todos os possíveis centróides da série, ou seja, a mesma quantidade de padrões de entrada.

Encontrar a quantidade de centróides que minimize o erro de teste, em geral, determina a melhor configuração de generalização para se realizar a previsão dos valores. Para a obtenção dos pesos lineares da RBF é executado, a cada iteração, o módulo *SolveLin*, apresentado na Figura 4.11, a seguir.

Módulo *SolveLin*

Entradas: Matriz $A1(c \times e)$ e $T(1 \times e)$

Calcular Matriz $Pe(c + 1 \times e)$: $Pe(i, j) = \begin{cases} A1(i, j), & \text{se } i \leq c \\ 1, & \text{se } i = c + 1 \end{cases}$

Processo da Pseudo-Inversa da Matriz Pe :

Calcular Matriz $M(c + 1 \times c + 1)$: $M = Pe * Pe'$

Calcular a Matriz inversa de M : M^{-1}

Calcular $GM(e \times c + 1)$: $GM = Pe' * M^{-1}$

A matriz GM é a Pseudo-Inversa da Matriz Pe

Calcular $W(1 \times c + 1)$: $W = T * GM$

Decompor $W(1 \times c + 1)$ em $W2(1 \times c)$ e $B2(1 \times 1)$ da seguinte forma:

$W2(i, j) = W(i, j), \forall i \text{ e } \forall j \leq c$

$B2(i, j) = W(i, j), \forall i \text{ e } \forall j > c$

Calcular $W2A1(1 \times e)$: $W2A1 = W2 * A1$

Calcular Matriz $Bias(1 \times e)$: $Bias(1, j) = B2(1, 1), \forall j = 1, \dots, e$

Calcular Matriz $A2(1 \times e)$: $A2(1, j) = W2A1(1, j) + Bias(1, j), \forall j = 1, \dots, e$

Saída: Matriz $A2(1 \times e)$

Fim Módulo *SolveLin*

FIGURA 4.11 – MÓDULO *SOLVELIN* DO MATLAB PARA A OBTENÇÃO DOS PESOS
FONTE: O AUTOR (2011)

A matriz $A2$ é a matriz saída da RBF com o ajuste do conjunto de treinamento. Ela possui e colunas as quais deveriam se aproximar ao máximo das e

saídas reais de cada padrão de entrada. Com estas duas matrizes, $A2$ e T , calcula-se o erro RMSE de treinamento da RBF. O período de teste é feito após encontrar o erro de ajuste da RBF, quando se apresentam os padrões separados para esta finalidade, a matriz $P1$. Calcula-se a distância euclidiana entre os padrões de $P1$ e os centróides da iteração, e aplica-se a função de ativação gaussiana, utilizando o módulo *RadBas*, obtendo assim os pesos entre a camada de entrada e a camada escondida (matriz $A1$) e utilizando-os para encontrar o RMSE de teste.

Com esta matriz de pesos definida e utilizando a matriz Alvo desses padrões de teste, a matriz $T1$, encontram-se os pesos entre as camadas escondida e de saída, através da aplicação do módulo *Sovelin*, e obtém-se a matriz $A2$, agora com os valores que deveriam ser os mesmos da matriz $T1$, ou pelo menos, muito próximo a eles. Assim, com estas duas últimas matrizes, calcula-se o erro RMSE do período de teste da RBF para a quantidade de centróides na iteração do momento.

Para esta primeira bateria de testes, foi escolhido o algoritmo de agrupamento explicado por ser um procedimento robusto e consagrado no meio acadêmico, principalmente por estar implementado no *software MATLAB®*. A partir desses testes foram escolhidos outros algoritmos de agrupamentos para a escolha dos centróides, já que essa definição influencia diretamente na qualidade e acurácia da previsão, ainda mais com o objetivo de escolher uma única configuração para todas as séries temporais diferentes relacionadas aos produtos de diferentes características.

4.3.1 Algoritmos de agrupamentos e realização de alguns testes preliminares

Uma vez definidos os parâmetros através dos quais se espera obter melhores resultados, o foco de estudo volta-se para o algoritmo de agrupamento, uma vez que a qualidade de previsão pode estar relacionada ao algoritmo de agrupamento escolhido. Como proposta deste trabalho, escolheu-se 4 algoritmos de agrupamentos:

- o próprio explicado anteriormente, implementado no *MATLAB®*;
- o modelo de programação linear binária exata que resolve o problema clássico das p -medianas;

- o algoritmo das k -médias e;
- o algoritmo de Teitz & Bart (1968).

A escolha desses algoritmos deu-se devido a:

- Algoritmo *MATLAB*® - Algoritmo amplamente usado devido a sua facilidade de acesso a usuários do software citado, variando o número de centróides de 1 a 48 (modelo 1).
- Modelo Exato – Uma vez que é necessário definir as medianas de um conjunto de pontos (padrões), a solução exata pode mostrar qual é o agrupamento ótimo no caso de escolher centróides entre os próprios pontos (padrões) de entrada e qual é a consequência dessa decisão na RBF, variando o número de centróides de 1 a 48 (modelo 2).
- Algoritmo das k -médias – Algoritmo mais difundido na literatura ao se programar as RBF. Na implementação do algoritmo das k -médias fez-se dois testes: o algoritmo tradicional e um algoritmo modificado, não encontrado na literatura quando utilizado como parte das RBF (modelos 3 e 4, respectivamente).
- Algoritmo de Teitz e Bart (1968) – Algoritmo heurístico que fornece boas soluções, de fácil implementação. Como este algoritmo aplicado nas RBF é uma inovação, fez-se três testes: Com 4 padrões para o período de teste, variando o número de centróides de 1 a 48 com o fator Spread como apresentado anteriormente e com uma mudança no cálculo desse fator e eliminando o período de teste variando o número de centróides de 1 a 52 (modelos 5, 6 e 7, respectivamente).

Com estes modelos pretende-se perceber o impacto que se tem ao variar o número de centróides e o algoritmo de agrupamento, ou forma de se escolher os centróides, ao se avaliar o erro de previsão cometido através do erro MAPE.

Para a realização desses 7 modelos propostos, com exceção do algoritmo executado pelo software *MATLAB*® (teste 1) já explicado, a RBF necessita dos mesmos elementos para a entrada no algoritmo. São eles, as matrizes $P(k \times e)$, $P1(k \times t)$, $T(1 \times e)$, $T1(1 \times t)$ e o Fator Spread (b), além do vetor que será utilizado para a previsão $P2(k \times 1)$ formado pelos últimos k valores de venda. A RBF foi

implementada conforme o pseudocódigo a seguir, apresentado na Figura 4.12, sendo alterado somente o algoritmo de agrupamento para cada teste.

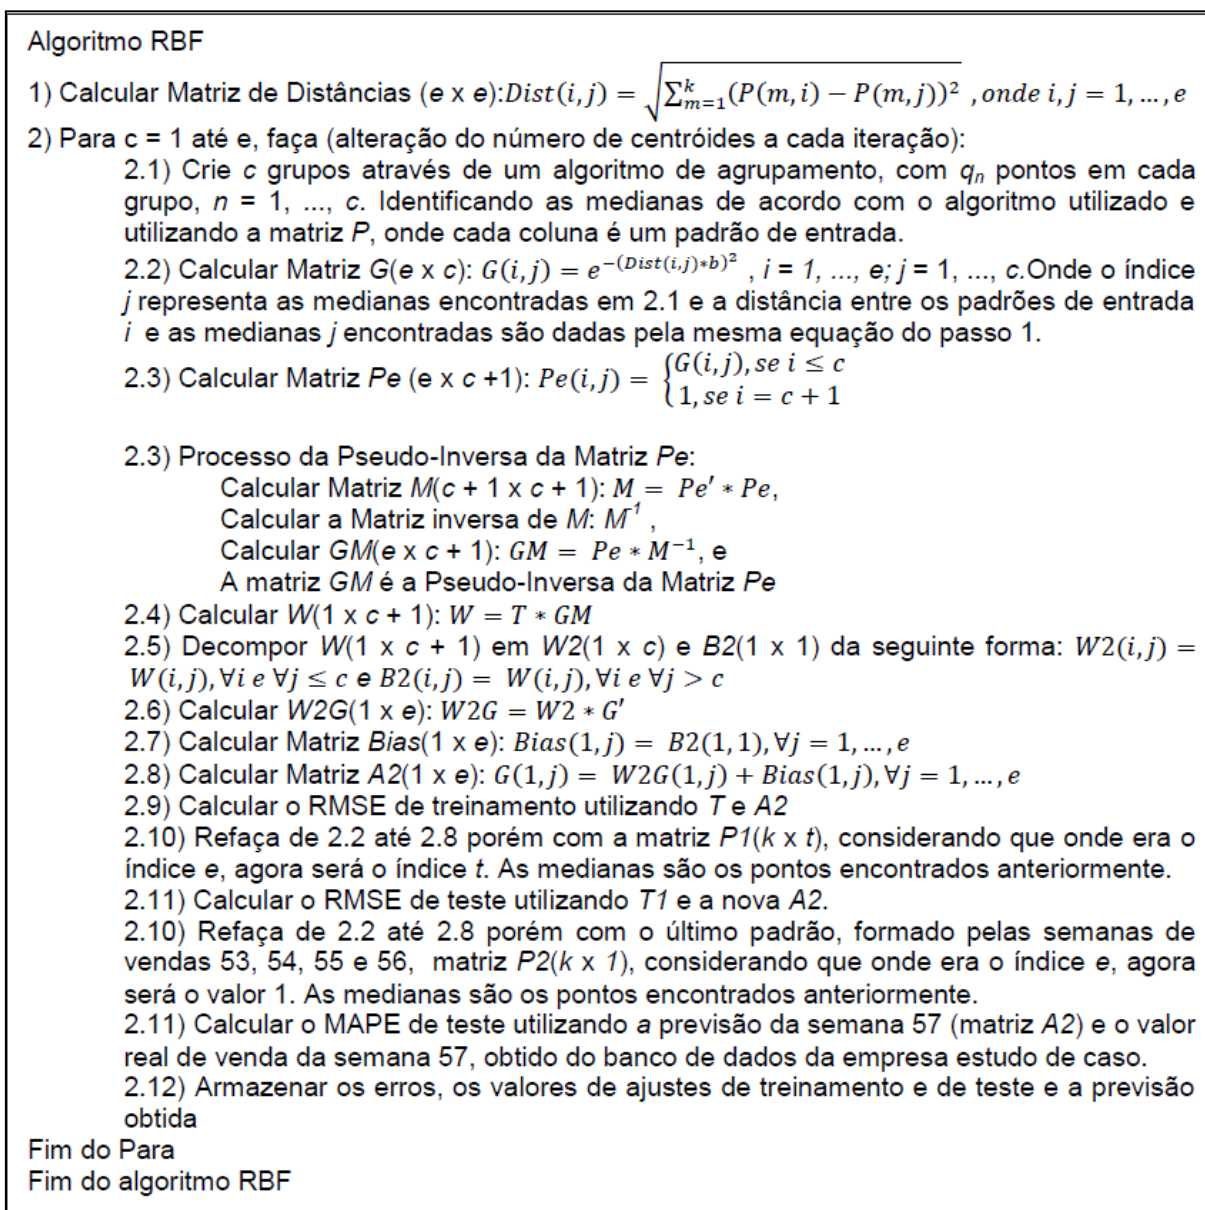


FIGURA 4.12 – ALGORITMO RBF
FONTE: O AUTOR (2011).

Com isso, são apresentados, a seguir, os 4 algoritmos de agrupamentos citados nos modelos e os comentários sobre as alterações propostas em cada um deles.

A. Modelo Exato

Para o modelo com o modelo exato (modelo 2) criou-se uma interface de comunicação através de linha de código entre a programação feita em *Visual Basic®* 6 e o software LINGO® 12. A cada iteração é lido um arquivo com a matriz de

distâncias entre os e padrões de entrada, a quantidade de centróides da iteração e o modelo de programação linear no formato do LINGO® 12 e o retorno são os pontos (ou padrões) encontrados como medianas pela solução do modelo linear.

O modelo gerado é baseado no problema clássico das p -medianas. O problema das p -medianas (PPM) pode ser formulado de acordo com o seguinte modelo matemático apresentado nas expressões matemáticas (4.4) a (4.8):

$$v(PPM) = \text{Min} \sum_{i \in N} \sum_{j \in N} d_{ij} x_{ij} \quad (4.4)$$

$$s. a. \quad \sum_{j \in N} x_{ij} = 1 \quad \forall i \in N \quad (4.5)$$

$$\sum_{j \in N} x_{jj} = p \quad (4.6)$$

$$x_{ij} \leq x_{jj} \quad \forall i, j \in N \quad (4.7)$$

$$x_{ij} \in \{0, 1\} \quad \forall i, j \in N \quad (4.8)$$

onde $[x_{ij}]_{n \times n}$ é uma matriz de alocação, com $x_{ij} = 1$ se o vértice i está alocado à mediana j , e $x_{ij} = 0$, caso contrário; $x_{jj} = 1$ se o vértice j é uma mediana e $x_{jj} = 0$, caso contrário.

A função objetivo (4.4) mostra que a distância total correspondente a uma solução de localização-alocação deve ser minimizada. O conjunto de restrições (4.5) impõe que cada vértice só poderá ser alocado a somente uma mediana. A restrição (4.6) refere-se ao número de medianas a serem localizadas. O conjunto de restrições (4.7) impede que algum vértice seja alocado a outro vértice que não seja mediana e, finalmente, o conjunto de restrições (4.8) condiciona as variáveis a receberem os valores inteiros binários 1 ou 0.

B. Algoritmo das k -médias

O algoritmo das k -médias necessita de um conjunto de pontos n dimensionais, uma métrica para cálculo das distâncias entre os pontos e o número k de grupos desejáveis. Neste trabalho, os pontos utilizados são os e padrões de

entrada das RBF, com cada ponto sendo de dimensão k , a métrica é a distância euclidiana e a quantidade de agrupamentos é representada pela variável c , definida pela quantidade de centróides que se deseja na iteração da RBF. Com isso, este algoritmo, utilizado no modelo 3, pode ser representado pelo pseudocódigo apresentado a seguir na Figura 4.13.

Algoritmo das k -médias

Entradas: $P(k \times e)$, c (quantidade de centróides na iteração)

1) Crie c grupos aleatoriamente, com q_n pontos em cada grupo, $n = 1, \dots, c$.

2) Encontre as medianas $m_n = (m_{n1}, m_{n2}, \dots, m_{nk})$ de cada grupo, onde cada elemento de

$$m_n \text{ é dado por: } m_{ni} = \frac{\sum_{j=1}^{q_n} p_{ji}}{q_n}, \forall i = 1, \dots, k \text{ e } p \in \text{Agrupamento } n$$

3) Designe cada ponto p a mediana m_n mais próxima, através da métrica de distância estabelecida, formando novos agrupamentos.

4) Recalcule as medianas para os novos agrupamentos.

5) Se não houver mudanças entre as medianas calculadas em 2 e em 4, então pare. Caso contrário, volte para 3, considerando as mediana calculadas em 4, as medianas calculadas em 2 da próxima iteração.

Saída: c centróides e os agrupamentos.

Fim do algoritmo das k -médias

FIGURA 4.13 – PSEUDO-CÓDIGO DO ALGORITMO DAS K -MÉDIAS

FONTE: O AUTOR (2011).

Uma alteração no algoritmo das k -médias utilizado no modelo 3 visa encontrar melhores agrupamentos, isto é, minimizar a distância de todos os pontos aos seus respectivos centróides, como o algoritmo tradicional das k -médias, porém utilizando outra dinâmica de cálculo.

A proposta é escolher c pontos quaisquer, fazendo deles os centróides iniciais, e para todos os outros pontos não selecionados primeiramente, insere-se um a um verificando a distância do ponto a ser inserido até a mediana mais próxima dele, determinando o agrupamento que este ponto deve permanecer. Após isso, recalcula-se a mediana do agrupamento alterado. Este algoritmo é utilizado no modelo 4 e representado pelo seguinte pseudocódigo da Figura 4.14.

Algoritmo das k -médias Modificado

Entradas: $P(k \times e)$, c (quantidade de centróides na iteração)

1) Selecione c pontos aleatoriamente. São as medianas no momento. Estes pontos são chamados agrupados, os $e - c$ não selecionados são chamados não agrupados.

2) Selecione um ponto p_i não agrupado e designe este ponto a mediana m_n ($n = 1$ até c) mais próxima pela métrica de distância estabelecida, insira p_i no agrupamento da mediana m_n . O ponto p_i passa a ser agrupado

3) Recalcule a mediana/centróide $m_n = (m_{n1}, m_{n2}, \dots, m_{nk})$ do agrupamento modificado ao se inserir

p_i , onde m_n é dado por: $m_{ni} = \frac{\sum_{j=1}^{q_n} p_{ji}}{q_n}$, $\forall i = 1, \dots, k$ e $p \in \text{Agrupamento } n$

4) Repita 2 e 3 até não existirem mais pontos não agrupados

Saída: c centróides e os agrupamentos.

Fim do algoritmo das k -médias Modificado

FIGURA 4.14 – PSEUDO-CÓDIGO DO ALGORITMO DAS K-MÉDIAS MODIFICADO
FONTE: O AUTOR (2011).

C. Algoritmo de Teitz e Bart (1968).

No modelo 5, a proposta é implementar o algoritmo consagrado de Teitz e Bart (1968) para encontrar as medianas que servirão de centróides na camada escondida da RBF. Uma consideração relevante neste momento é que nos modelos 1 e 2, os centróides encontrados são pontos escolhidos entre os pontos (padrões) de entrada da RBF, isto é, medianas do conjunto inicial de pontos, já nos modelos 3 e 4, os centróides podem não ser nenhum ponto do conjunto inicial.

O algoritmo de Teitz e Bart (1968) tem como saída os agrupamentos e as medianas, isto é, são escolhidos pontos, dentre o conjunto de pontos apresentado ao algoritmo, para serem as medianas e, por consequência os centróides a serem usados na RBF.

No algoritmo de Teitz e Bart, inicialmente escolhem-se um conjunto S formado por p pontos, considerado como uma aproximação do conjunto \bar{v}_p das medianas. Verifica-se se algum ponto $v_i \in V - S$ pode substituir, de acordo com o algoritmo abaixo, algum ponto $v_j \in V$, produzindo um novo conjunto S' tal que: $S' = S \cup \{v_i\} - \{v_j\}$ e $\sigma(S') < \sigma(S)$. Se isto for possível, substituímos v_j por v_i e S' é considerado uma nova aproximação para o conjunto \bar{S} , onde nenhuma substituição de pontos produza um número de transmissão menor. O pseudocódigo para este algoritmo é o apresentado na Figura 4.15.

Algoritmo de Teitz e Bart (1968)
 Entradas: $P(k \times e)$, c (quantidade de centróides na iteração)
 1) Construa um conjunto inicial S , com p elementos de V .
 2) Rotule todos os pontos $v_i \notin S$ como “não-analisados”
 3) Enquanto existirem pontos “não-analisados” no conjunto $V - S$, faça:
 3.1) Selecione um vértice “não-analisado” $v_i \in V - S$, e calcule a redução Δ_{ij} do número de transmissão, $\forall v_j \in S: \Delta_{ij} = \sigma(S) - \sigma(S \cup \{v_i\} - \{v_j\})$
 3.2) Faça $\Delta_{ijo} = \max_{v_j \in S} [\Delta_{ij}]$
 Se $\Delta_{ijo} > 0$ faça $S = S \cup \{v_i\} - \{v_j\}$
 Se $\Delta_{ijo} \leq 0$ rotule v_i como “analisado”.
 4) Se durante a execução do passo anterior ocorrer modificações no conjunto S , volte para o passo 2. Caso contrário PARE. O conjunto S será uma aproximação para o problema das p -medianas.
 Saída: c medianas (centróides) e os agrupamentos.
 Fim do algoritmo de Teitz e Bart (1968)

FIGURA 4.15 – PSEUDO-CÓDIGO DO ALGORITMO DE TEITZ E BART (1968).
 FONTE: O AUTOR (2011).

No modelo 6, a modificação foi apenas no fator *Spread* b , onde esta variável deixou de ter a potência 2, ficando o cálculo da Matriz G , no passo 2.2 da RBF implementada, da seguinte forma apresentada em (4.9).

$$G(e \times c): G(i, j) = e^{-Dist(i, j)^2 * b}, i = 1, \dots, e; j = 1, \dots, c \quad (4.9)$$

Esta alteração faz com que o valor da distância após a ativação da função gaussiana, entre o ponto i e o centróide j , seja menor (o raio do campo receptivo), fazendo com que a influência de cada centróide seja maior na solução final através dos pesos entre a camada de entrada e a escondida.

Finalmente, no modelo 7 a proposta é eliminar o período de testes da RBF, fazendo somente o treinamento da RBF com todos os padrões de entrada e a previsão, isto é, a matriz P passaria a ter $e + t$ colunas (padrões de entrada) a matriz T passaria a ter $e + t$ colunas (valores alvo para cada padrão) e os passos 2.10 e 2.11 não são executados.

5 TESTES E RESULTADOS COM AS RBF

Embora o foco deste trabalho seja encontrar uma configuração para a RBF que minimize o erro de previsão para o conjunto de todos os produtos e, com isso, melhorar o sistema de reposição, apresenta-se o resultado referente ao tempo computacional gasto nos modelos para que possa mostrar a viabilidade operacional da metodologia desenvolvida. Também são apresentados os erros cometidos nos períodos de treinamentos, testes e previsão de cada um dos modelos realizados. Estes erros são apresentados com uma contagem de quantidades de séries a cada nível de erro cometido.

Para a realização dos testes computacionais foi utilizado um computador com processador Intel® Core 2 Duo E8400, com 4GB de memória RAM, em um sistema de 32 bits. Na Tabela 5.1 são apresentados os tempos médios para cada fase da RBF: treinamento, teste e previsão, e também o total do tempo gasto em média com a previsão de uma série temporal definida uma quantidade de centróides. Ainda nesta mesma Tabela 5.1 são apresentados os tempos totais, em horas, para processar todas as 9396 séries temporais, em dois casos: definida uma quantidade de centróide para cada série temporal e; variando a quantidades de centróides de 1 a t , a cada série temporal.

TABELA 5.1 – TEMPOS COMPUTACIONAS GASTOS NOS TESTES

	Tempo Computacional médio para cada Série Temporal (seg.)				Tempo em HORAS para rodar 9396 séries, com uma quantidade de centróides definida	Tempo em HORAS para rodar 9396 séries, testando de 1 a t centróides
	Treino	Teste	Previsão	Total		
Modelo 1	0,028	0,000252	8,56E-05	0,028	0,073	3,5
Modelo 2	3,545	0,000077	2,30E-05	3,545	9,251	444,1
Modelo 3	0,021	0,000200	5,40E-05	0,021	0,054	2,6
Modelo 4	0,256	0,000199	5,35E-05	0,256	0,669	32,1
Modelo 5	0,249	0,000032	9,68E-06	0,249	0,650	31,2
Modelo 6	0,327	0,000061	1,69E-05	0,327	0,853	40,9
Modelo 7	0,290	0,000000	2,06E-05	0,290	0,757	39,4

FONTE: O AUTOR (2011).

Pode-se observar na Tabela 5.1 que o tempo de processamento total difere consideravelmente entre os testes com aplicação de heurísticas de agrupamento e o modelo exato para solução das p -medianas. Percebe-se também que dentre todos

os modelos testados, aquele que utiliza o algoritmo das k -médias tradicional (modelo 3) e o algoritmo implementado no software MATLAB® (modelo 1) foram os mais rápidos, seguidos pelos testes com o algoritmo de Teitz e Bart (1968), (modelos 5, 6 e 7) e o modelo com o algoritmo das k -médias modificado (modelo 4). O teste com a resolução do modelo exato teve um tempo de execução extremamente alto em relação aos outros testes.

Essa diferença justifica-se pelo fato de que é preciso, através da programação computacional, acessar o *software* LINGO®, inserir o modelo, resolvê-lo e retornar a solução para o programa desenvolvido em linguagem *Visual Basic* 6, o que compromete o tempo computacional do modelo. Um aspecto importante para a avaliação da aplicabilidade das RBF, em situações reais de previsão de grande quantidade de produtos, é a comparação do tempo total em prever 9396 séries testando todas as possibilidades de centróides e considerando que a quantidade de centróides seja definida em um único valor, o qual será alvo de discussão posterior.

Percebe-se que a diferença é muito acentuada e isso pode comprometer a aplicação em grande escala caso seja necessário testar várias quantidades de centróides para escolher a melhor configuração da RBF. Definir a quantidade de centróides é uma tarefa que implica diretamente na aplicabilidade em grande escala das RBF para cálculo da previsão e, conseqüentemente, da reposição desses produtos.

Vale salientar que os tempos computacionais apresentados neste trabalho são, mesmo os mais rápidos, excessivos ao se comparar ao processamento de computadores com processador mais potente, com maior capacidade de memória RAM, e com programação paralela podendo ser desenvolvida. Portanto a relação do tempo computacional apresentado serve como uma referência comparativa de tempo total entre modelos, e não em tempo total de processamento, o qual sob outras circunstâncias computacionais seria totalmente diferente.

Os resultados relacionados à previsão e aos testes sobre as configurações da RBF e os resultados sobre a aplicação do sistema de reposição e os níveis de ruptura são apresentados separadamente. Os resultados sobre as configurações mostram a respeito dos parâmetros da RBF, em relação aos testes feitos e a qualidade da solução de previsão em cada deles, visando assim obter a desejada configuração que minimize o erro de previsão geral. Os resultados sobre a aplicação das previsões no sistema de reposição, relacionados à ruptura, apresentam os

níveis de ruptura real da empresa estudo de caso, com um acompanhamento diário por quase um ano, após a implementação da metodologia de reposição proposta neste trabalho, inclusive com a previsão dos produtos sendo realizada através da RBF.

Considerando sempre o objetivo de encontrar uma configuração que possa minimizar o erro de previsão, apresenta-se um estudo sobre o período de treinamento e testes de cada série temporal. O RMSE é a métrica de erro escolhida e os níveis de erros são de até 100, separados em 10 faixas de igual amplitude e mais uma faixa com erro acima do valor 100. O valor colocado nas tabelas de resultados são as quantidades de séries temporais que ficaram com erros dentro das faixas estipuladas e as médias de erros em cada uma das faixas.

TABELA 5.2 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS RMSE NO TREINAMENTO

Mod.	RMSE treino	entre 0 e 10	entre 10 e 20	entre 20 e 30	entre 30 e 40	entre 40 e 50	entre 50 e 60	entre 60 e 70	entre 70 e 80	entre 80 e 90	entre 90 e 100	maior que 100	Total
1	Qtde	3804	1197	849	631	489	407	343	283	223	173	997	9396
	%	40,5%	12,7%	9,0%	6,7%	5,2%	4,3%	3,7%	3,0%	2,4%	1,8%	10,6%	100%
	% ac.	40,5%	53,2%	62,3%	69,0%	74,2%	78,5%	82,2%	85,2%	87,5%	89,4%	100%	
2	Qtde	3351	1066	800	644	490	433	391	339	287	229	1366	9396
	%	35,7%	11,3%	8,5%	6,9%	5,2%	4,6%	4,2%	3,6%	3,1%	2,4%	14,5%	100%
	% ac.	35,7%	47,0%	55,5%	62,4%	67,6%	72,2%	76,4%	80,0%	83,0%	85,5%	100%	
3	Qtde	2467	727	675	598	468	435	419	392	355	298	2562	9396
	%	26,3%	7,7%	7,2%	6,4%	5,0%	4,6%	4,5%	4,2%	3,8%	3,2%	27,3%	100%
	% ac.	26,3%	34,0%	41,2%	47,5%	52,5%	57,2%	61,6%	65,8%	69,6%	72,7%	100%	
4	Qtde	3187	1037	820	644	506	442	394	347	292	238	1489	9396
	%	33,9%	11,0%	8,7%	6,9%	5,4%	4,7%	4,2%	3,7%	3,1%	2,5%	15,8%	100%
	% ac.	33,9%	45,0%	53,7%	60,5%	65,9%	70,6%	74,8%	78,5%	81,6%	84,2%	100%	
5	Qtde	2742	860	757	609	497	418	421	389	342	304	2057	9396
	%	29,2%	9,2%	8,1%	6,5%	5,3%	4,4%	4,5%	4,1%	3,6%	3,2%	21,9%	100%
	% ac.	29,2%	38,3%	46,4%	52,9%	58,2%	62,6%	67,1%	71,2%	74,9%	78,1%	100%	
6	Qtde	2717	879	758	592	503	419	406	377	347	302	2096	9396
	%	28,9%	9,4%	8,1%	6,3%	5,4%	4,5%	4,3%	4,0%	3,7%	3,2%	22,3%	100%
	% ac.	28,9%	38,3%	46,3%	52,6%	58,0%	62,5%	66,8%	70,8%	74,5%	77,7%	100%	
7	Qtde	2707	878	770	600	497	420	417	397	342	320	2048	9396
	%	28,8%	9,3%	8,2%	6,4%	5,3%	4,5%	4,4%	4,2%	3,6%	3,4%	21,8%	100%
	% ac.	28,8%	38,2%	46,3%	52,7%	58,0%	62,5%	66,9%	71,2%	74,8%	78,2%	100%	

FONTE: O AUTOR (2011).

A Tabela 5.2 apresenta a quantidade de séries temporais, em cada modelo, que resultaram em erros RMSE em cada faixa estipulada (Qtde), o percentual (%) de séries temporais em cada faixa e o percentual acumulado (% ac.) em ordem crescente da faixa de erro, em relação ao período de treinamento da RBF, chamado também de ajuste da série.

O RMSE possui a mesma ordem de grandeza dos valores medidos, portanto quanto mais próximo de zero este valor melhor é o ajuste entre os valores obtidos neste período e os valores desejados como saída. Percebe-se que o modelo 1

(MATLAB®) é o único teste que possui mais de 50% das séries temporais ajustadas com erros menores do que 20, sendo este o melhor modelo em relação ao ajuste de treinamento. Percebe-se também que o modelo 2 (modelo linear exato), possui o segundo melhor resultados em relação ao ajuste de testes, seguido pelo modelo 4 (*k*-médias modificado).

Por fim, pode-se perceber que os modelos 5, 6 e 7, resultam em ajustes melhores que o modelo 3, isto é, os centróides escolhidos dentre os conjuntos de padrões de entrada, se comportam melhor do que os centróides que não pertencem ao conjunto de padrões de entrada. Assim, pode-se verificar uma tendência de melhor ajuste do período de treinamento para algoritmos de agrupamentos onde se escolhe os centróides da camada escondida dentre os pontos considerados do conjunto de padrões de entrada da RBF.

TABELA 5.3 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS RMSE NO TESTE

Mod.	RMSE teste	entre 0 e 10	entre 10 e 20	entre 20 e 30	entre 30 e 40	entre 40 e 50	entre 50 e 60	entre 60 e 70	entre 70 e 80	entre 80 e 90	entre 90 e 100	maior que 100	Total
1	Qtde	2264	575	510	456	402	369	332	314	289	263	3622	9396
	%	24,1%	6,1%	5,4%	4,9%	4,3%	3,9%	3,5%	3,3%	3,1%	2,8%	38,5%	100%
	% ac.	24,1%	30,2%	35,6%	40,5%	44,8%	48,7%	52,2%	55,6%	58,7%	61,5%	100%	
2	Qtde	2425	565	534	475	401	375	345	321	291	270	3394	9396
	%	25,8%	6,0%	5,7%	5,1%	4,3%	4,0%	3,7%	3,4%	3,1%	2,9%	36,1%	100%
	% ac.	25,8%	31,8%	37,5%	42,6%	46,8%	50,8%	54,5%	57,9%	61,0%	63,9%	100%	
3	Qtde	2217	601	536	476	406	361	330	307	285	264	3613	9396
	%	23,6%	6,4%	5,7%	5,1%	4,3%	3,8%	3,5%	3,3%	3,0%	2,8%	38,5%	100%
	% ac.	23,6%	30,0%	35,7%	40,8%	45,1%	48,9%	52,4%	55,7%	58,7%	61,5%	100%	
4	Qtde	2347	591	561	492	426	380	349	319	298	272	3361	9396
	%	25,0%	6,3%	6,0%	5,2%	4,5%	4,0%	3,7%	3,4%	3,2%	2,9%	35,8%	100%
	% ac.	25,0%	31,3%	37,2%	42,5%	47,0%	51,1%	54,8%	58,2%	61,3%	64,2%	100%	
5	Qtde	2442	622	569	494	429	389	367	338	301	273	3172	9396
	%	26,0%	6,6%	6,1%	5,3%	4,6%	4,1%	3,9%	3,6%	3,2%	2,9%	33,8%	100%
	% ac.	26,0%	32,6%	38,7%	43,9%	48,5%	52,6%	56,5%	60,1%	63,3%	66,2%	100%	
6	Qtde	2339	612	569	487	432	388	365	334	303	276	3191	9396
	%	24,9%	6,5%	6,1%	5,2%	4,6%	4,1%	3,9%	3,6%	3,2%	4,0%	34,0%	100%
	% ac.	24,9%	31,4%	37,5%	42,6%	47,2%	51,4%	55,3%	58,8%	62,0%	66,0%	100%	

FONTE: O AUTOR (2011).

A Tabela 5.3 apresenta os mesmo dados que a Tabela 5.2, porém relacionados ao período de teste da RBF. O modelo 7 não é apresentado nesta tabela justamente pela característica do teste ser a realização da previsão sem o período de teste. Percebe-se que o modelo 5 (algoritmo de Teitz e Bart (1968)) é o melhor teste em relação ao erro de teste. O modelo 6, também com o algoritmo de agrupamento baseado nas medianas escolhidas pelo algoritmo de Teitz & Bart (1968), fornece resultados tão bons quanto o do modelo 5, assim como o modelo 2 (modelo linear).

O modelo 4 (*k*-médias modificado) possui resultados piores que estes, mas melhores que o modelo 1 (MATLAB®) e o modelo 3 (*k*-médias tradicional), o qual

obteve os piores resultados em relação ao período de teste. Deste modo pode-se perceber novamente uma tendência em que centróides escolhidos dentre os padrões de entrada da RBF, geram melhores resultados.

Uma consideração que deve ser feita com relação ao RMSE do período de treinamento e de teste da RBF é o fato de que um RMSE de 10, por exemplo, pode significar um valor excelente se os valores desejados estão próximos de 200, por exemplo, mas pode ser considerado péssimo se os valores desejados estão na ordem de grandeza de 10 também.

A medida de erro RMSE é altamente utilizada na literatura e, devido a isso, utilizada neste trabalho também. Assim, este trabalho tem também como proposta a utilização do erro MAPE, porém para a medição do erro de previsão, ficando o RMSE de treino e de ajuste para calibração da RBF e ajuste dos parâmetros. Assim sendo, o resultado principal é alcançado através da medida de erro MAPE da previsão realizada com a RBF treinada e testada. O MAPE está separado em 10 faixas de erros, agrupados a cada 10%, e mais uma faixa com erros de previsão acima dos 100%. Os resultados são apresentados na Tabela 5.4.

A Tabela 5.4 apresenta os mesmo dados que a Tabela 5.2, porém relacionados a previsão realizada pela RBF, uma vez que se conhecia o valor real de venda para período que a previsão era realizada. O MAPE retorna o desvio absoluto em percentual do valor desejado pelo obtido, portanto quanto mais próximo de zero este valor melhor é a previsão realizada.

TABELA 5.4 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS MAPE NA PREVISÃO

Mod.	MAPE Prev.	entre 0 e 10	entre 10 e 20	entre 20 e 30	entre 30 e 40	entre 40 e 50	entre 50 e 60	entre 60 e 70	entre 70 e 80	entre 80 e 90	entre 90 e 100	maior que 100	Total
1	Qtde	1996	1911	1281	967	658	418	294	250	167	185	1269	9396
	%	21,2%	20,3%	13,6%	10,3%	7,0%	4,4%	3,1%	2,7%	1,8%	2,0%	13,5%	100%
	% ac.	21,2%	41,6%	55,2%	65,5%	72,5%	77,0%	80,1%	82,7%	84,5%	86,5%	100%	
2	Qtde	1947	1968	1316	1000	665	452	321	295	261	513	658	9396
	%	20,7%	20,9%	14,0%	10,6%	7,1%	4,8%	3,4%	3,1%	2,8%	5,5%	7,0%	100%
	% ac.	20,7%	41,7%	55,7%	66,3%	73,4%	78,2%	81,6%	84,8%	87,5%	93,0%	100%	
3	Qtde	2145	2036	1329	985	632	404	266	235	147	167	1050	9396
	%	22,8%	21,7%	14,1%	10,5%	6,7%	4,3%	2,8%	2,5%	1,6%	1,8%	11,2%	100%
	% ac.	22,8%	44,5%	58,6%	69,1%	75,9%	80,2%	83,0%	85,5%	87,0%	88,8%	100%	
4	Qtde	2179	2068	1358	988	631	399	261	233	144	164	971	9396
	%	23,2%	22,0%	14,5%	10,5%	6,7%	4,2%	2,8%	2,5%	1,5%	1,7%	10,3%	100%
	% ac.	23,2%	45,2%	59,7%	70,2%	76,9%	81,1%	83,9%	86,4%	87,9%	89,7%	100%	
5	Qtde	2079	2099	1335	1043	641	433	277	271	202	363	653	9396
	%	22,1%	22,3%	14,2%	11,1%	6,8%	4,6%	2,9%	2,9%	2,1%	3,9%	6,9%	100%
	% ac.	22,1%	44,5%	58,7%	69,8%	76,6%	81,2%	84,2%	87,0%	89,2%	93,1%	100%	
6	Qtde	2083	2075	1339	1040	631	423	290	278	218	326	693	9396
	%	22,2%	22,1%	14,3%	11,1%	6,7%	4,5%	3,1%	3,0%	2,3%	3,5%	7,4%	100%
	% ac.	22,2%	44,3%	58,5%	69,6%	76,3%	80,8%	83,9%	86,8%	89,2%	92,6%	100%	
7	Qtde	2080	2098	1350	1035	616	432	286	274	206	364	655	9396
	%	22,1%	22,3%	14,4%	11,0%	6,6%	4,6%	3,0%	2,9%	2,2%	3,9%	7,0%	100%
	% ac.	22,1%	44,5%	58,8%	69,8%	76,4%	81,0%	84,0%	87,0%	89,2%	93,0%	100%	

FONTE: O AUTOR (2011).

O modelo 7 (algoritmo de Teitz e Bart (1968) sem a realização do período de teste) apresenta, a partir de 10% de erro, os melhores resultados de previsão, isto é, é o modelo que, comparativamente aos outros modelos, apresentam mais séries temporais com erros de previsão mais baixos. Pode-se perceber isso, também verificando que apenas 655 séries temporais tiveram erros que divergiram e apresentaram erros maiores que 100%. Entretanto, os modelos 5 e 6 (também com o (algoritmo de Teitz e Bart (1968)) e o modelo 2 (modelo linear exato) resultaram previsões de melhor qualidade em mais séries temporais do que nos modelos 1, 3 e 4.

O modelo 4 (*k*-médias modificado) possui resultados piores, porém próximos dos resultados dos melhores modelos. Além disso, para erros MAPE de até 50%, este modelo foi o que resultou na maior quantidade de séries temporais, com aproximadamente 70% das séries temporais com erros menores que 50%. Mais uma vez, pode-se perceber novamente uma tendência em que centróides escolhidos dentre os padrões de entrada da RBF, geram melhores resultados.

Deve-se considerar também que para um produto com valores na ordem de grandeza próximo de 1, quando a previsão, por exemplo, deveria ser 1, mas retorna um valor 3 têm-se 200% de erro MAPE, mas esse valor de erro não condiz com um erro operacionalmente importante, pois se fosse 200%, em uma previsão que necessita de 350 unidades, por exemplo, ter-se-ia ou uma superestocagem ou a probabilidade grande de ruptura, o que não acontece na diferença entre 1 e 3 unidades.

Deste modo, agora observando as características de cada uma das séries temporais testadas, viu-se que dentre as 9396 séries testadas, 810 séries temporais estavam relacionadas a produtos classificados como CC, na classificação apresentada. Estes produtos possuem uma característica muito peculiar, que é o baixíssimo giro dentro da semana, sendo bem comum a venda de menos de 2 unidades neste período. Assim, estes produtos não atingem, com sua previsão, a quantidade mínima de uma caixa para a reposição e dentro do sistema de reposição proposto, eles são controlados de uma forma especial, apresentada posteriormente

Assim sendo, percebe-se no modelo 1 (MATLAB®) e no modelo 3 (*k*-médias tradicional) previsões com erros de mais de 100% em mais de 810 séries. No modelo 4 (*k*-médias modificado) a quantidade ficou muito próxima desse valor,

sendo que as séries que ultrapassaram os 100% de erro MAPE e que não estão classificadas como CC, são referentes às séries temporais de vendas de produtos classificados como CB. Apresenta-se então os resultados de previsão retirando-se as 810 séries temporais referentes aos produtos CC, os quais são apresentados na Tabela 5.5.

TABELA 5.5 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS MAPE NA PREVISÃO SEM OS PRODUTOS CLASSIFICADOS COMO CC

Mod.	RMSE treino	entre 0 e 10	entre 10 e 20	entre 20 e 30	entre 30 e 40	entre 40 e 50	entre 50 e 60	entre 60 e 70	entre 70 e 80	entre 80 e 90	entre 90 e 100	maior que 100	Total
1	Qtde	1996	1911	1281	967	658	418	294	250	167	185	459	8586
	%	23,2%	22,3%	14,9%	11,3%	7,7%	4,9%	3,4%	2,9%	1,9%	2,2%	5,3%	100%
	% ac.	23,2%	45,5%	60,4%	71,7%	79,4%	84,2%	87,6%	90,6%	92,5%	94,7%	100%	
2	Qtde	1947	1968	1316	1000	665	452	321	295	261	361	0	8586
	%	22,7%	22,9%	15,3%	11,6%	7,7%	5,3%	3,7%	3,4%	3,0%	4,2%	0,0%	100%
	% ac.	22,7%	45,6%	60,9%	72,6%	80,3%	85,6%	89,3%	92,8%	95,8%	100%	100%	
3	Qtde	2145	2036	1329	985	632	404	266	235	147	167	240	8586
	%	25,0%	23,7%	15,5%	11,5%	7,4%	4,7%	3,1%	2,7%	1,7%	1,9%	2,8%	100%
	% ac.	25,0%	48,7%	64,2%	75,6%	83,0%	87,7%	90,8%	93,5%	95,3%	97,2%	100%	
4	Qtde	2179	2068	1358	988	631	399	261	233	144	164	161	8586
	%	25,4%	24,1%	15,8%	11,5%	7,3%	4,6%	3,0%	2,7%	1,7%	1,9%	1,9%	100%
	% ac.	25,4%	49,5%	65,3%	76,8%	84,1%	88,8%	91,8%	94,5%	96,2%	98,1%	100%	
5	Qtde	2079	2099	1335	1043	641	433	277	271	202	206	0	8586
	%	24,2%	24,4%	15,5%	12,1%	7,5%	5,0%	3,2%	3,2%	2,4%	2,4%	0,0%	100%
	% ac.	24,2%	48,7%	64,2%	76,4%	83,8%	88,9%	92,1%	95,2%	97,6%	100%	100%	
6	Qtde	2083	2075	1339	1040	631	423	290	278	218	209	0	8586
	%	24,3%	24,2%	15,6%	12,1%	7,3%	4,9%	3,4%	3,2%	2,5%	2,4%	0,0%	100%
	% ac.	24,3%	48,4%	64,0%	76,1%	83,5%	88,4%	91,8%	95,0%	97,6%	100%	100%	
7	Qtde	2080	2098	1350	1035	616	432	286	274	206	209	0	8586
	%	24,2%	24,4%	15,7%	12,1%	7,2%	5,0%	3,3%	3,2%	2,4%	2,4%	0,0%	100%
	% ac.	24,2%	48,7%	64,4%	76,4%	83,6%	88,6%	92,0%	95,2%	97,6%	100%	100%	

FONTE: O AUTOR (2011).

Assim vê-se que, com o erro de até 50%, o teste 4 possui a maior quantidade de séries temporais, mostrando que é um algoritmo de agrupamento que possui uma boa tendência de resultar boas previsões, isto é, abaixo de 50% de erro MAPE. Entretanto ao se analisar todo o conjunto de séries temporais, vê-se que o modelo 5 e o modelo 7 (sem o período de teste) possuem um desempenho melhor em relação aos outros modelos. Isto é, nota-se que os melhores resultados são obtidos quando os centróides são escolhidos dentre os padrões de entrada.

Até este momento da análise não se fez considerações em relação a quantidade de centróides que se deve utilizar para finalizar a configuração que minimize o erro de previsão dos produtos como um todo. Então se apresenta na Tabela 5.6 os resultados dos modelos retirando as 810 séries relacionadas a produtos CC, porém dada para cada quantidade de centróide. Os resultados

apresentados são as médias de erro geral em todas as 8586 séries por modelo e pela quantidade de centróides.

TABELA 5.6 – ERROS MÉDIOS DE PREVISÃO NOS TESTES PELO NÚMERO DE CENTRÓIDES

Centróide	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7
1	22,4	26,0	23,9	23,9	26,0	26,0	25,9
2	22,5	28,3	22,5	22,7	28,4	28,4	28,4
3	22,6	28,7	22,4	22,4	28,6	28,8	28,7
4	22,6	28,9	22,3	22,3	28,7	28,8	28,7
5	22,9	29,1	22,3	22,2	29,0	29,2	28,9
6	23,0	29,3	22,4	22,4	29,2	29,2	29,2
7	23,0	29,5	22,4	22,4	29,3	29,4	29,2
8	23,3	29,7	22,5	22,5	29,3	29,6	29,3
9	23,5	30,0	22,5	22,5	29,3	29,6	29,4
10	23,5	30,0	22,7	22,7	29,3	29,7	29,5
11	23,8	29,9	23,0	22,7	29,6	29,7	29,6
12	23,9	30,1	23,2	22,9	29,6	29,8	29,6
13	24,2	30,3	23,3	22,8	29,6	30,0	29,7
14	24,4	30,3	23,3	22,9	29,9	29,8	29,8
15	24,8	30,5	23,7	23,2	29,9	30,0	29,9
16	25,1	30,5	24,0	23,6	29,8	29,7	30,0
17	25,4	30,9	24,1	23,7	29,9	29,9	30,1
18	25,8	30,9	24,5	23,8	30,2	29,9	30,0
19	26,0	31,1	24,7	24,1	30,1	29,7	30,1
20	26,2	31,1	25,0	24,4	30,1	30,0	30,2
21	26,6	31,3	25,6	24,3	30,0	29,9	30,2
22	26,9	31,1	25,8	24,5	30,1	29,9	30,2
23	27,1	31,5	26,4	24,9	29,9	29,7	30,2
24	27,5	31,5	26,5	25,3	29,9	29,7	30,2
25	27,6	31,7	26,9	25,5	29,5	29,6	30,2
26	27,9	31,6	27,2	25,6	29,6	29,5	30,1
27	28,1	31,8	27,3	26,1	29,5	29,5	29,5
28	28,5	32,0	28,0	26,4	29,6	29,5	29,8
29	28,8	32,0	28,2	26,7	29,3	29,1	29,5
30	29,3	32,3	28,6	27,2	29,5	29,1	29,6
31	29,5	32,3	28,6	27,1	29,2	28,8	29,2
32	30,2	32,5	29,1	27,6	29,3	29,0	29,4
33	30,5	32,7	29,5	28,1	29,2	28,6	29,1
34	30,8	32,6	29,2	28,2	29,0	28,7	29,3
35	31,4	32,6	29,9	29,1	29,3	28,5	28,9
36	31,8	32,9	30,2	29,1	28,8	28,7	29,1
37	32,3	32,9	30,6	29,5	28,7	28,5	28,9
38	32,6	32,8	31,0	30,5	28,5	28,3	28,8
39	33,0	33,1	30,7	30,7	28,4	28,2	28,7
40	33,2	33,2	30,9	31,1	28,4	28,1	28,8
41	33,7	33,4	30,7	31,5	28,1	27,8	28,4
42	34,3	33,5	30,9	32,3	28,0	27,7	28,5
43	34,9	33,8	31,3	33,2	27,7	27,5	28,2
44	35,3	33,8	31,4	33,6	27,6	27,2	28,2
45	35,3	34,3	31,8	33,8	27,5	27,1	28,0
46	35,6	34,4	31,8	34,5	27,1	26,8	28,0
47	36,6	34,5	32,4	35,0	26,9	26,5	27,7
48	38,8	35,0	31,9	35,5	26,8	26,3	27,6
49	-	-	-	-	-	-	27,3
50	-	-	-	-	-	-	27,0
51	-	-	-	-	-	-	26,6
52	-	-	-	-	-	-	27,0

FONTE: O AUTOR (2011).

Em primeiro lugar, percebe-se nos resultados que a média de erro de previsão é consideravelmente menor que a encontrada na empresa estudo de caso antes da aplicação desta metodologia. Pois, antes o erro médio geral de previsão era de aproximadamente 50% e com os testes, o resultado se aproxima de 30%. Percebe-se também que quanto maior o número de centróides maior é a tendência de aumentar o erro de previsão, o que vai de encontro ao resultado apresentados na literatura.

Este fenômeno explica-se dentro do conceito das Redes Neurais como sendo o “*overfitting*”, ou super treinamento, onde a RNA aprende em demasia sobre os dados do período de treinamento e não consegue o desejado poder de generalização e o aprendizado artificial para novos padrões de entrada. A Figura 5.1 apresenta o comportamento de generalização da RBF em cada teste e a evolução das médias de erros de previsão ao se aumentar o número de centróides.




FIGURA 5.1 – GRÁFICO COMPARATIVO: ERROS PELO NÚMERO DE CENTRÓIDES
FONTE: O AUTOR (2011).

Pode-se notar que o modelo 4, possui a menor média geral de erro de previsão quando se aplica a RBF com 5 centróides (22,2%), isto é, cerca de 10% do número de padrões de entrada. Também pode se notar que os modelos com a aplicação do algoritmo de Teitz e Bart (1968), tem uma tendência de aumentar com poucos centróides e diminuir ao se aproximar do máximo de centróides possíveis (quantidade t) para a RBF.

Assim, com todas as informações sobre os erros de treinamento, teste e previsão, além da análise da melhor quantidade de centróides, chega-se a uma configuração que se aproxima da melhor previsão geral de todos os produtos, dando assim, maior robustez ao sistema de reposição proposto no decorrer do presente trabalho.

5.1 DISCUSSÃO DOS RESULTADOS E PROPOSTAS DE MELHORIAS PARA A RBF

Uma vez analisados todos os modelos, propõem-se seguinte configuração da RBF para se obter melhores resultados gerais em razão do erro médio MAPE de previsão dentre todos os produtos, excetos os classificados como CC. Estes serão contemplados no sistema de reposição proposto mais adiante no trabalho.

O algoritmo de *k*-médias modificado apresentado possui os melhores resultados para a minimização do erro de previsão no geral, mas percebe-se nos modelos a tendência de que se forem escolhidos centróides dentre os padrões de entrada então os resultados tendem a ser mais robustos, com menor índice de divergência do erro.

Uma vez que se tenham definidos os parâmetros: 4 valores de vendas semanas seguidas para se compor um padrão de entrada, com o valor desejado de saída desse padrão o valor de venda da semana seguinte (quinta semana). O método de suavização dos dados mais robusto foi o proposto neste trabalho, resultando em melhores valores, no geral. O valor do parâmetro *BSpread* pode ficar próximo a 1 com o valor *Spread* igual a 0,83.

O período de teste deve ser no máximo 10% do número de padrões de entrada, sendo que pode se tornar dispensável, uma vez que o modelo 7 mostrou-se com resultados de previsão gerais tão bons quanto o modelo 4. Além disso, pode-se observar que os últimos padrões de entrada não devem ser retirados do período de treinamento. Sendo assim, quando determina-se a quantidade de padrões para o período de teste, sugere-se escolher aleatoriamente padrões que não estejam entre os últimos 10% da série temporal. Neste caso, define-se que o período de teste deve ser realizado com 4 padrões somente, escolhidos por sorteio entre o primeiro e o

quadragésimo quarto padrão de entrada, deixado assim os padrões 45, 46, 47 e 48, obrigatoriamente no conjunto de padrões para o período de treinamento. O erro do período de teste pode ser usado como parâmetro da metodologia de ponto de reposição ou revisão periódica apresentado em Ballou (2006).

O algoritmo de k -médias modificado resultou em melhores resultados ao se utilizar 5 centróides na camada escondida. Assim a sugestão deste trabalho fica em fazer uma alteração no algoritmo de k -médias modificado, sendo este implementado e sugerido com proposta inovadora no algoritmo de Redes Neurais Artificiais de Bases Radiais aplicadas à previsão de séries temporais. A alteração proposta é a inserção do passo 5, apresentado na Figura 5.2 a seguir, no algoritmo de k -médias modificado.

Algoritmo das k -médias Proposto

Entradas: $P(k \times e)$, c (quantidade de centróides na iteração)

1) Selecione c pontos aleatoriamente. São as medianas no momento. Estes pontos são chamados agrupados, os $e - c$ não selecionados são chamados não agrupados.

2) Selecione um ponto p_i não agrupado e designe este ponto a mediana m_n ($n = 1$ até c) mais próxima pela métrica de distância estabelecida, insira p_i no agrupamento da mediana m_n . O ponto p_i passa a ser agrupado

3) Recalcule a mediana/centróide $m_n = (m_{n1}, m_{n2}, \dots, m_{nk})$ do agrupamento modificado ao se inserir

p_i , onde m_n é dado por: $m_{ni} = \frac{\sum_{j=1}^{q_n} p_{ji}}{q_n}$, $\forall i = 1, \dots, k$ e $p \in \text{Agrupamento } n$

4) Repita 2 e 3 até não existirem mais pontos não agrupados

5) Uma vez definidos os c centróides (m_n) no passo 4, faça:

Para cada mediana/centróide m_n , $n = 1$ até c

$m_n = p_n^*$, onde $\{p_n^* \in P, p_n^* = \min(\text{distância}(p_i, m_n), \forall i = 1, \dots, e)\}$

Assim, m_n são agora medianas dos pontos dados em P e serão usadas como os centróides.

Saída: c centróides e os agrupamentos.

Fim do algoritmo das k -médias Proposto

FIGURA 5.2 – PROPOSTA PARA O ALGORITMO DAS K-MÉDIAS PARA A RBF
FONTE: O AUTOR (2011).

Para validar a proposta apresentam-se, na Tabela 5.7, os resultados obtidos com a configuração já definida, variando o número de centróides de 1 até 10, dando mais evidência a quantidade de 5 centróides.

TABELA 5.7 – CONTAGEM DE SÉRIES TEMPORAIS POR ERROS MAPE NA PREVISÃO COM A APLICAÇÃO DA RBF PROPOSTA

Quant. de Centróide	MAPE Prev.	entre 0 e 10	entre 10 e 20	entre 20 e 30	entre 30 e 40	entre 40 e 50	entre 50 e 60	entre 60 e 70	entre 70 e 80	entre 80 e 90	Total	Erro Médio
1	Qtde	2377	2350	1395	1148	575	347	156	175	63	8586	22,56%
	%	27,7%	27,4%	16,2%	13,4%	6,7%	4,0%	1,8%	2,0%	0,7%	100%	
	% ac.	27,7%	55,1%	71,3%	84,7%	91,4%	95,4%	97,2%	99,3%	100%		
2	Qtde	2590	2403	1419	1061	480	333	156	144	0	8586	20,96%
	%	30,2%	28,0%	16,5%	12,4%	5,6%	3,9%	1,8%	1,7%	0,0%	100%	
	% ac.	30,2%	58,2%	74,7%	87,0%	92,6%	96,5%	98,3%	100%	100%		
3	Qtde	2559	2488	1431	1017	499	321	171	100	0	8586	20,68%
	%	29,8%	29,0%	16,7%	11,8%	5,8%	3,7%	2,0%	1,2%	0,0%	100%	
	% ac.	29,8%	58,8%	75,4%	87,3%	93,1%	96,8%	98,8%	100%	100%		
4	Qtde	2580	2463	1474	1010	463	329	153	114	0	8586	20,66%
	%	30,0%	28,7%	17,2%	11,8%	5,4%	3,8%	1,8%	1,3%	0,0%	100%	
	% ac.	30,0%	58,7%	75,9%	87,7%	93,1%	96,9%	98,7%	100%	100%		
5	Qtde	2626	2423	1454	1024	489	309	171	90	0	8586	20,54%
	%	30,6%	28,2%	16,9%	11,9%	5,7%	3,6%	2,0%	1,0%	0,0%	100%	
	% ac.	30,6%	58,8%	75,7%	87,7%	93,4%	97,0%	99,0%	100,0%	100,0%		
6	Qtde	2612	2444	1426	1008	525	311	156	104	0	8586	20,65%
	%	30,4%	28,5%	16,6%	11,7%	6,1%	3,6%	1,8%	1,2%	0,0%	100%	
	% ac.	30,4%	58,9%	75,5%	87,2%	93,3%	97,0%	98,8%	100%	100%		
7	Qtde	2607	2445	1440	994	517	335	155	93	0	8586	20,68%
	%	30,4%	28,5%	16,8%	11,6%	6,0%	3,9%	1,8%	1,1%	0,0%	100%	
	% ac.	30,4%	58,8%	75,6%	87,2%	93,2%	97,1%	98,9%	100%	100%		
8	Qtde	2619	2369	1487	1015	524	316	152	104	0	8586	20,74%
	%	30,5%	27,6%	17,3%	11,8%	6,1%	3,7%	1,8%	1,2%	0,0%	100%	
	% ac.	30,5%	58,1%	75,4%	87,2%	93,3%	97,0%	98,8%	100%	100%		
9	Qtde	2609	2370	1517	1007	512	302	165	104	0	8586	20,71%
	%	30,4%	27,6%	17,7%	11,7%	6,0%	3,5%	1,9%	1,2%	0,0%	100%	
	% ac.	30,4%	58,0%	75,7%	87,4%	93,3%	96,9%	98,8%	100%	100%		
10	Qtde	2609	2398	1473	998	534	311	160	103	0	8596	20,73%
	%	30,4%	27,9%	17,2%	11,6%	6,2%	3,6%	1,9%	1,2%	0,0%	100%	
	% ac.	30,4%	58,3%	75,5%	87,1%	93,3%	96,9%	98,8%	100,0%	100,0%		

FONTE: O AUTOR (2011).

Na Tabela 5.7 pode-se notar que a metodologia proposta proporcionou melhores resultados na previsão do conjunto de produtos classificados como A, B, CA e CB. Nota-se que o erro médio diminuiu de 22,2% para 20,54%, porém, o resultado mais importante é que todas as previsões das séries temporais obtiveram erros menores que 80%, exceto com um centróide. Vê-se, também, que são maiores as quantidades de séries com erros menores que 20%, aumentando a confiabilidade de previsão da metodologia proposta em relação às testadas.

A Figura 5.3 mostra a evolução dos erros de previsão MAPE, ao se realizar os testes com a configuração definida e a metodologia de escolha dos centróides proposta, evidenciando os melhores resultados para 5 centróides como era de se esperar.




FIGURA 5.3 – QUANTIDADE DE CENTRÓIDES X ERROS MÉDIOS DE PREVISÃO
 FONTE: O AUTOR (2011).

Assim, tem-se na metodologia proposta para a configuração da RBF uma excelente direção para se desenvolver mais estudos de forma a melhorar a previsão de séries temporais de diferentes características.

É importante salientar que o problema exposto neste trabalho também é uma inovação, uma vez que não existe na literatura trabalhos que discutam a necessidades de metodologias de previsão únicas para um conjunto de séries temporais com diferentes características de comportamento. Seja observando a tendência, sazonalidade, período de ciclo e ruído branco. Pretende-se levar essa discussão ao âmbito acadêmico e literário para que possa encontrar metodologias de inteligência artificial de forma que se adapte a característica dos dados, sem a interferência do decisor e sem a necessidade de infindáveis testes sobre a configuração de determinado algoritmo heurístico ou meta-heurístico.

Assim, o presente trabalho pretende contribuir com o estado da arte levando um problema de maior porte do que simplesmente prever uma série temporal, e sim tentar prever um conjunto de séries temporais sem a necessidade de se trocar parâmetros ou com excessivo gasto de tempo computacional, quando se tem um sistema computacional complexo e não dedicado somente a tarefa de previsão.

6 PROPOSTA PARA O SISTEMA DE REPOSIÇÃO E RESULTADOS

O sistema de reposição de estoque deve ser efetivo nas organizações, ou seja, deve suprir as demandas de vendas e, ao mesmo tempo, não causar superestocagem nas lojas. As administrações modernas têm buscado constantemente por novas ferramentas que possam auxiliá-las na busca da excelência de seus processos. A metodologia sugerida neste trabalho visa estabelecer parâmetros para a reposição automática dos produtos, minimizando os índices de ruptura e auxiliando na tomada de decisão sobre os estoques.

Para cada produto de cada loja da rede varejista, calculam-se os níveis de estoque de acordo com os dias de cobertura definido pela política de estoque da empresa. Para este cálculo, toma-se por base o histórico de vendas, cujos dados são preparados, ajustados e, em seguida, os mesmos são aplicados a um sistema de previsão de vendas. O método de previsão aqui utilizado são as RNA de funções de Bases Radiais (RBF).

A quantidade de vendas prevista (obtida através das RBF) é utilizada para a definição, dia-a-dia, dos parâmetros de reposição. Estes parâmetros, por sua vez, são cruzados com as informações de estoque real do fim do dia de modo a sugerir a reposição automática, via sistema, de cada um dos produtos. O processo geral da metodologia está representado na Figura 6.1 e a explicação detalhada de cada passo é apresentada logo nas seções seguintes.

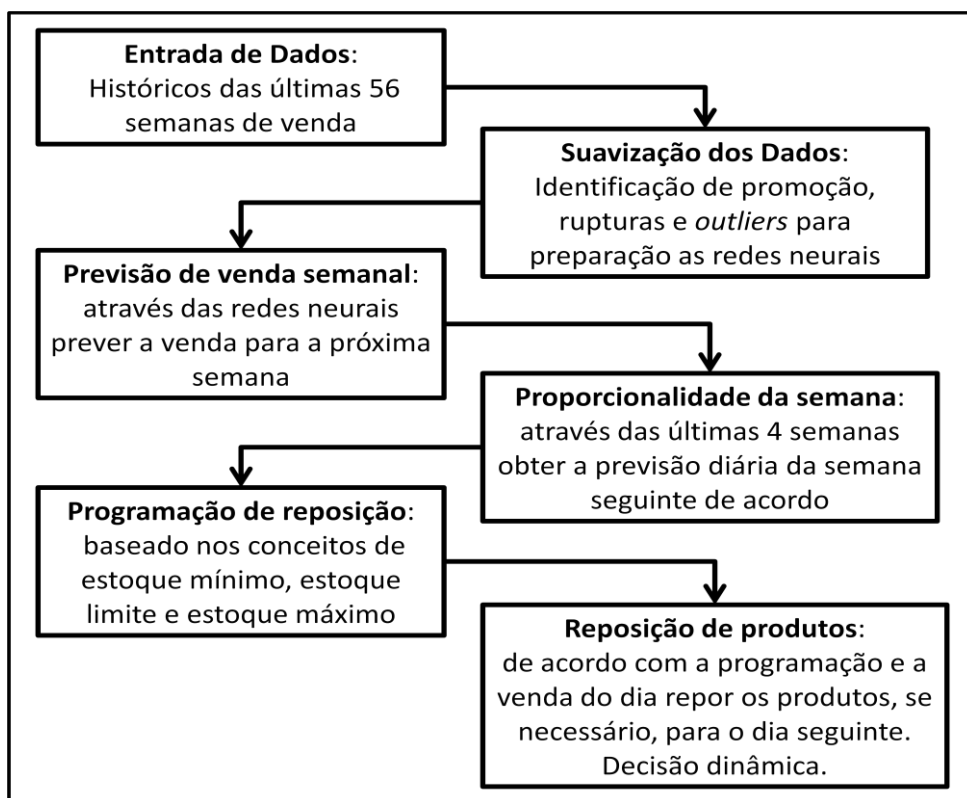


FIGURA 6.1 – ESQUEMA GERAL DA PROPOSTA PARA O SISTEMA DE REPOSIÇÃO
FONTE: O AUTOR (2009).

O foco principal da proposta apresentada é a utilização de uma técnica de previsão de vendas para o cálculo dos valores de estoque mínimo, limite e máximo para a reposição do estoque de cada um dos produtos nas lojas (SCARPIN e STEINER, 2011).

6.1 UTILIZAÇÃO DA PREVISÃO DE VENDAS

A gestão da informação é um aspecto crítico para a otimização da distribuição física de uma cadeia de suprimentos e para a elevação do nível de serviço oferecido aos clientes. Tem sido tema de muitas publicações e de muita discussão no âmbito empresarial. Possuir uma previsão de vendas confiável é uma informação cada dia mais importante, pois com ela, a empresa pode melhorar o nível de serviço, antecipando ações de modo a suprir a demanda dos clientes.

A reposição de produtos nas lojas deve ser capaz de atender a demanda diária de venda, cobrir um período determinado e, também, não causar

superestocagem nas lojas. A RBF utilizada permite um procedimento rápido de atualização de pesos, separa os padrões de entrada e apresenta uma estrutura apta à construção de mapeamentos locais dos dados de entrada e saída.

A Tabela 6.1, mostra a previsão encontrada para as semanas 57 e 58 (para o produto “Água Sanitária” de 1 litro), das 56 semanas utilizadas para alimentar as RBF. Percebeu-se que, em todos os produtos, para a segunda semana de previsão com as mesmas 56 semanas de entrada no algoritmo, o desvio de previsão aumenta, e este fato justifica a utilização do algoritmo semanalmente.

TABELA 6.1 – PREVISÃO DE VENDA PARA DUAS SEMANAS

Produto	Descrição	Data	Previsão	Venda Real	Erro de Previsão (%)
365378	Água Sanitária 1l	04/02/2008	715	679	5,30191458
365378	Água Sanitária 1l	11/02/2008	612	568	7,746478873

FONTE: O AUTOR (2009).

6.2 CÁLCULO DOS LIMITES

Uma vez que se tenha o valor de previsão de venda para a semana seguinte de cada um dos produtos de cada loja, calculam-se, então, os valores limites de estoque. Para isso, deve-se dividir o valor previsto para uma semana em valores de venda para cada um dos dias daquela semana. Utiliza-se a proporcionalidade do dia como previsão diária.

O valor previsto é considerado 100% das vendas para a próxima semana, o valor percentual de cada dia da semana, de segunda-feira a domingo, é calculado pela média percentual da participação de vendas das últimas quatro semanas. Por exemplo, do valor total de venda da semana 53, o percentual do valor de venda em relação a esse total da segunda-feira é de 14,4%, o percentual da segunda-feira da semana 54 é 18% do total de venda da semana 54, e assim como das semanas 55 e 56 são, respectivamente, 16,5% e 15,1%. A média desses quatro percentuais (14,4%, 18%, 16,5% e 15,1%) é 16%, logo, a quantidade de produtos prevista para a venda da segunda-feira da semana 57 é 16% do valor previsto nas RBF.

De forma similar, calculam-se os valores de vendas para os demais dias da semana. Como no fim de semana, a reposição de produtos é feita somente no

sábado (aos domingos não é realizada a operação de reposição), então as quantidades previstas de venda de sábado e domingo são somadas e o fim de semana (sábado e domingo) é considerado como um único dia.

De acordo com a política de estoque da empresa, define-se a quantidade de dias que a reposição do produto deve suprir. Com base nessa cobertura de dias (três dias, por exemplo), cria-se o conceito de valores de estoque mínimo, estoque limite e estoque máximo, e se faz os respectivos cálculos.

O estoque mínimo de um produto para um determinado dia é o valor de previsão para aquele dia; o estoque máximo é a soma dos valores de previsão subseqüentes dos dias de cobertura e o estoque limite é a média aritmética entre o mínimo e o máximo. Como alternativa, o estoque limite pode ser utilizado também com um conceito de cobertura mínima, isto é, uma quantidade de produtos que supre a venda de certo número de dias, sendo esta soma menor do que o estoque máximo.

Seja a previsão de vendas para o produto “Água Sanitária”, para uma determinada semana, de 408 unidades, conforme a Tabela 6.2. Conforme explicado anteriormente, divide-se esse valor e, proporcionalmente, obtêm-se as quantidades de vendas previstas para cada dia da semana, determinando assim o estoque mínimo que a loja deve possuir em cada dia.

Neste exemplo, determinou-se que a cobertura de estoque é de três dias e que a cobertura mínima, ou seja, o estoque limite deve cobrir dois dias. Assim, o estoque limite de segunda-feira é a soma do valor previsto para segunda e terça ($75 + 51 = 126$) e o estoque máximo é a soma dos valores de estoque mínimo de segunda, terça e quarta ($75 + 51 + 48 = 174$). Para estoque máximo de sexta-feira, e estoque limite e máximo do fim de semana utilizam-se os valores de segunda e terça, ou então, executa-se novamente a previsão de venda novamente no meio de semana.

TABELA 6.2 – EXEMPLO DE CÁLCULO DOS VALORES DE ESTOQUE – ÁGUA SANITÁRIA

Estoque	Segunda	Terça	Quarta	Quinta	Sexta	Fim de Semana
Mínimo	75	51	48	59	51	124
Limite	126	99	107	110	175	199
Máximo	174	158	158	324	250	250

FONTE: O AUTOR (2009).

6.3 ESTRATÉGIA DE REPOSIÇÃO E EXEMPLOS NUMÉRICOS

De posse das informações de estoque, cruzam-se essas informações com o estoque real do produto no fim do dia. Se o estoque real for menor que o estoque limite, baseado no cálculo do sistema de reposição por ponto de pedido (BALLOU, 2006), calcula-se a diferença entre o estoque máximo e o estoque real, baseado no cálculo do sistema de reposição de revisão periódica (BALLOU, 2006), este valor encontrado é a sugestão de reposição do produto para o dia seguinte. Com isso, pode-se estabelecer os parâmetros de cobertura da estratégia de reposição que mais convier para a empresa e de acordo com a classificação de produtos mais adequada ao caso real que se está utilizando.

Um sistema chamado Min-Max de cálculo de reposição de estoques utiliza este mesmo conceito de encontrar um estoque limite ou ponto de pedido e pedir uma quantidade de estoque igual a diferença do valor máximo e o estoque atual, como feito na reposição por revisão periódica. A proposta inovadora está no fato de que os valores são atualizados conforme a previsão de vendas obtida na RBF e a divisão proporcional da semana, além do novo conceito de cobertura de dias, olhando para o valor de previsão do dia e não em uma média de vendas diária (MDV). Assim cria-se uma visão estratégica diferenciada, com cálculos de quantidade de reposição e pontos de pedido dinâmicos e de acordo com os acontecimentos futuros e acompanhamento sistêmico diário.

Além disso, este sistema proposto considera o fato de produtos não terem giro suficiente para que a previsão de vendas gerada seja suficientemente capaz de fornecer o valor exato de venda futuro. Estes produtos são basicamente os classificados como CC, chamados de baixo ou baixíssimo giro. Neste trabalho consideram-se os produtos como sendo baixo/baixíssimo giro aqueles que vendem menos de 10 unidades por mês. Para todos estes produtos então, a estratégia de reposição é basicamente ter como estoque limite $1/3$ (um terço) da quantidade de uma caixa ou SKU de movimento, e quando o produto diminuir dessa quantidade no estoque da loja, então se gera automaticamente um pedido de uma caixa do produto. É importante comentar que para a venda do produto na loja, não se pode ficar com uma quantidade muito baixa, como uma ou duas unidades, pois, assim,

este produto pode não ter visibilidade para o cliente e, conseqüentemente, não gerar venda.

Este novo conceito de visualizar a reposição traz um benefício a gestão: organizar suas ações logística e comerciais baseado no comportamento de venda futura do consumidor e não somente na média de venda passada ocorrida. Assim, ao se colocar um valor de previsão para cada dia da próxima semana e fazer a reposição baseada nestes valores, podem-se oscilar os níveis de estoque da loja, minimizando os erros de estoque por dia, superestocagem e ruptura. Cria-se, dessa forma, mais tempo para a gerência tomar decisões em outras áreas da loja, como limpeza da loja, organização, promoções e atendimento ao cliente.

Os dias de cobertura para o cálculo de estoque máximo podem ser definidos por produto (sistema de reposição por ponto de pedido) ou por característica mercadológica (pedidos em conjunto). Assim, pode-se definir para produtos com alto giro, poucos dias de cobertura e, para produtos de baixo e baixíssimo giro, um número maior de dias de cobertura, para não ficar com quantidades ínfimas de estoque e não proporcionar visibilidade a estes produtos.

Ao se definir os dias de cobertura, deve-se considerar a operação logística envolvida no processo. Assim, quando é sugerida a reposição automática de um produto, considera-se que a reposição será efetuada na gôndola no meio do período seguinte em diante, e este período deve ser suprido com o estoque atual.

O acerto de dias de cobertura influencia diretamente na periodicidade de reposição, pois quanto maior os dias de cobertura, menor é a quantidade de reposições e, conseqüentemente, maior o risco de se ter uma superestocagem; já por outro lado, se forem poucos os dias de cobertura, maior será a quantidade de reposições e, conseqüentemente, mais enxuto será o estoque, com maior risco de se ter a ruptura do produto.

Deste modo, encontrar para cada produto ou para cada grupo mercadológico a quantidade de dias de cobertura de estoque máximo da loja é um ajuste que deve ser planejado conjuntamente entre o gerente logístico e o gerente da loja, ficando o sistema de reposição proposto adequado para qualquer decisão tomada.

O caso de estudo para a aplicação desta metodologia é uma rede de supermercados e hipermercados com 33 lojas, sendo que cada loja possui, em média 8.000 produtos diferentes, conforme já comentado no capítulo 2. Assim, tem-

se 264.000 (8.000 x 33) previsões a serem feitas por semana. Definiu-se um período de cobertura de quatro dias para produtos de alto giro, cinco dias para médio giro, seis dias para baixo giro e 15 dias para baixíssimo giro. O programa desenvolvido demora em média 13 minutos para a previsão de todos os produtos de uma loja, ou seja, 429 minutos ou aproximadamente 7 horas para todas as lojas, sendo que a programação de reposição é dada semanalmente.

Na Tabela 6.3 apresenta-se uma comparação entre as estratégias de reposição, a atual e a proposta neste trabalho. Primeiramente, deve-se analisar que o estoque real no fim do dia 03/02/2008 (Domingo) é de 186 unidades, enquanto o estoque simulado considera que neste domingo o estoque é zerado. Define-se o estoque simulado deste modo a fim de comparar o comportamento do estoque no fim do dia de cada estratégia sem que a estratégia atual interfira nos resultados da simulação. Lembrando que o Estoque Mínimo utilizado é a previsão de demanda do dia.

TABELA 6.3 – EXEMPLO COMPARATIVO DE SISTEMAS DE REPOSIÇÃO: REAL X SIMULADO

Data (02/2008)	Dia da Semana	Promoção	Venda Real	Est. Mín.	Est. Limite	Est. Máx.	Est. Real (fim do dia)	Reposição Real	Est. Simulado (fim do dia)	Reposição Simulada
3	Domingo	não	XXX	XXX	XXX	XXX	186	XXX	0	XXX
4	Segunda-feira	não	4	22	41	60	182	0	56	60
5	Terça-feira	não	3	19	38	58	179	0	53	0
6	Quarta-feira	não	6	19	39	64	173	0	47	0
7	Quinta-feira	não	28	20	45	93	145	0	19	0
8	Sexta-feira	não	29	25	73	93	116	0	64	74
9	Sábado	não	32	48	68	85	144	60	53	21
10	Domingo	não	16	48	68	85	128	XXX	37	XXX
11	Segunda-feira	não	12	20	37	54	164	48	25	0
12	Terça-feira	não	11	17	34	52	153	0	41	27
13	Quarta-feira	não	18	17	35	57	135	0	23	0
14	Quinta-feira	não	24	18	40	75	111	0	51	52
15	Sexta-feira	não	24	22	57	77	87	0	53	26
16	Sábado	não	30	35	55	72	105	48	42	19
17	Domingo	não	6	35	55	72	99	XXX	36	XXX

FONTE: O AUTOR (2009).

Após a implantação da estratégia, o estoque real deverá estabilizar nos níveis de estoque desejado pelo algoritmo em alguns dias, dependendo da quantidade em estoque de cada produto. Este tempo não é relevante para a estratégia proposta, pois o algoritmo determinará que não se faça reposições do produto enquanto o estoque real não estiver nos níveis desejados. Este fato também é um fator importante na estratégia de reposição proposta, pois o nível de estoque,

com a metodologia de reposição proposta, tende a se estabilizar rapidamente após uma perturbação mercadológica.

Percebe-se na Tabela 6.3, que a quantidade de reposições no estoque simulado pelo algoritmo é maior do que na estratégia atual, gerando mais trabalho operacional. Porém, o nível de estoque do produto na loja é mais enxuto, entre 15% e 60% a menos de produto armazenado no estoque da loja e com um estoque de segurança suficiente para a venda do dia. Quando simulada a nova estratégia para todos os produtos percebe-se, de um modo geral, que a quantidade de reposições por produto aumenta, porém a quantidade de produto a cada reposição diminui consideravelmente, garantindo um estoque mais enxuto nas lojas e não abrindo mão do estoque de segurança para evitar a ruptura.

Por exemplo, no dia 07/02/2008 (quinta-feira), temos que ao final do dia, no estoque simulado, o produto está com estoque de 19 unidades; como esse valor é menor que o estoque limite do dia seguinte, 08/02/2008, de 73 unidades, então é gerado automaticamente no sistema um pedido de reposição do produto que será entregue na loja no período da manhã do dia 08/02/2008, de 74 unidades, ficando com um estoque de 93 unidades (estoque máximo de sexta-feira) que deverá suprir a demanda das vendas deste dia, de sábado (09/02/2008) e de domingo (10/02/2008). A venda de sexta-feira, 08/02/2008, foi de 29 unidades, ficando, ao fim do dia, com um estoque de 64 unidades.

Pode-se observar que ao fim do dia de domingo (10/12/2008), o estoque é de 37 unidades, a mesma quantidade de estoque limite de segunda-feira (11/02/2008), não gerando assim reposição na segunda-feira, nesta simulação. Vale lembrar que não se faz reposições nos domingos, por esse motivo considera-se que o estoque mínimo, limite e máximo do fim de semana são baseados na soma de previsão para sábado e domingo. Por exemplo, no sábado (16/02/2008), a previsão retorna um valor de 21 unidades e domingo (17/02/2009) a previsão de venda é de 14 unidades, assim considera-se o valor de estoque mínimo para o fim de semana como sendo a soma destas previsões, ou seja, 35 unidades.

Na Figura 6.2, a seguir, tem-se um exemplo gráfico fictício da programação de reposição de um produto de médio giro para duas semanas seguidas. No primeiro dia de aplicação do planejamento estratégico proposto, vê-se que o estoque real da loja, para este produto (Água Sanitária), está superestimado. Esta era uma

das situações encontradas antes da aplicação do método sendo que, neste caso, estava ocorrendo a superestocagem com o produto.

Deve-se perceber que no dia 4 o valor de venda deve ser comparado com o estoque simulado do fim do dia anterior, isto é, o estoque simulado do dia 3, e também se deve analisar que no dia seguinte pode ocorrer a reposição do produto. Deste modo, fica evidente que o nível de estoque simulado sempre está maior do que a quantidade de venda, e que fica muito abaixo do estoque real que utiliza na estratégia atual a previsão por médias móveis. O gráfico mostra que a estratégia atual garante sempre um estoque de segurança e, ainda, traz a níveis mais enxutos a quantidade de cada produto disponível, gerando assim mais economia para a rede supermercadista.




FIGURA 6.2 – COMPARAÇÃO DOS NÍVEIS DE ESTOQUE: ATUAL E PROPOSTA
FONTE: O AUTOR (2009).

Toda vez que, em certo dia, o nível de estoque simulado está menor que o valor de estoque limite então, para o próximo dia será feita a sugestão automática de reposição. Por exemplo, nos dias 4, 5, 6, 7, 8, 10, 12, 13, 14 ocorre esta situação. Porém, pode-se perceber que no dia 7 isto também ocorre, mas como o dia 7 é um domingo e não há reposição para este dia, então não é feita a sugestão. Verifica-se que o estoque real está entre 87 a 186 unidades na loja, e considerando que a venda deste produto está, em média, entre 3 a 32 produtos por dia, pode-se perceber que existe uma superestocagem deste produto. Ainda na Figura 6.2, verifica-se que as linhas de estoque máximo e de estoque mínimo, se aproximam nos dias 6, 7 e 8, ocorrendo também nos dias 13 e 14. Isso acontece por que dia 6 é

sábado e o estoque máximo é influenciado pelo estoque de segunda-feira, dia 8. De modo análogo, tal fato acontece para o dia 13 também.

A metodologia proposta neste trabalho foi aplicada a empresa estudo de caso e acompanhada por aproximadamente 11 meses, de 03/01/2011 até 24/11/2011. Os resultados reais dos níveis de ruptura mostram uma tendência para os hipermercados de um nível de ruptura entre 0,5% e 0,8%, e os supermercados entre 1,5% e 2% de ruptura. A Figura 6.3 mostra a evolução dos níveis de ruptura a medida que os parâmetros de dias foram sendo ajustados de acordo com o dia-a-dia da empresa, descobrindo para cada conjunto de produtos, a chamada divisão mercadológica, qual quantidade de dias para cálculo do estoque máximo e estoque limite.




FIGURA 6.3 – NÍVEIS DE RUPTURAS REAIS DO ESTUDO DE CASO
FONTE: O AUTOR (2011).

O gráfico apresenta uma tendência de queda à medida que vão sendo ajustados os parâmetros de reposição de acordo com a loja, e a divisão mercadológica dos produtos. Vale salientar que a empresa tem implementada a metodologia em seu sistema desde 2009, chegando a patamares como os apresentados anteriormente, porém em 2010 e 2011, a empresa aumentou em 6 lojas hipermercados a sua rede, distorcendo esses níveis de meados de 2010 até julho/agosto de 2011.

7 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

A proposta deste trabalho foi sugerir uma ferramenta matemática computacional aplicada ao planejamento operacional de reposição de produtos de uma rede de lojas de supermercados com base em previsões de vendas. A previsão obtida toma por base a análise de séries temporais, a qual alimenta o algoritmo RBF, obtendo um valor de previsão de venda. Este valor previsto é utilizado no cálculo de limites de estoque, os quais são atualizados de acordo com o dia da semana e previsão de consumo para os dias seguintes.

Para isso, foi necessária uma pesquisa sobre as características dos parâmetros do algoritmo de Redes Neurais Artificiais de Bases Radiais (RBF). O objetivo era encontrar uma configuração mais adequada para aplicar em todos os produtos, sem ter a necessidade de treinar as RBF com diversos tipos de configurações, variando número de valores no padrão de entrada, número de padrões separados para o conjunto de teste, dimensão dos campos receptivos e, principalmente, a quantidade de centróides na camada escondida.

Primeiramente, utilizando um algoritmo já implementado no software MATLAB®, foram testados 81 configurações diferentes para 9396 séries temporais, representando 116 produtos durante 81 semanas de acompanhamento. Uma vez definidos os parâmetros iniciais, o estudo voltou-se para melhorar o algoritmo da RBF através de escolhas mais adequadas para os centróides da Rede Neural. Para isso, foram utilizadas três técnicas adicionais, além da já implementada nos primeiros testes, para determinar quais eram os melhores centróides. Assim encarou-se o problema de escolher os centróides como sendo um problema clássico de p -medianas. Neste sentido, aplicou-se, além do algoritmo implementado no software MATLAB®, o modelo linear, o algoritmo de k -médias e uma variação deste, e o algoritmo de Teitz e Bart (1968), com três variações dentro da RBF, totalizando sete modelos diferentes.

Com os resultados obtidos, percebeu-se que o modelo linear exato resulta em bons resultados para a previsão com a RBF, entretanto o tempo computacional e a necessidade de um software para resolver o modelo, criam uma “barreira computacional” para problemas com grandes quantidades de produtos. O modelo com o algoritmo de k -médias resultou em um tempo computacional muito menor em

relação as demais técnicas, mas as previsões não atingiram a acurácia obtida nos outros algoritmos; porém o modelo com o algoritmo de *k*-médias modificado, mesmo sendo mais lento, mas sem maiores implicações, resultou nas melhores previsões com a RBF com poucos centróides.

O algoritmo de Teitz e Bart (1968), considerando os três modelos feitos, resultou em uma estabilidade de previsão, isto é, não sofria uma alteração significativa no erro MAPE de previsão ao se alterar a quantidade de centróides, apesar de que esses erros de previsão foram um pouco acima do que nos testes com outras técnicas utilizando poucos neurônios na camada oculta, mas compensando esses erros, em relação as outras técnicas, nas previsões cujas RBF tinham muitos neurônios (centróides).

Observando os resultados de ajuste da RBF, no período de treinamento e no período de teste, além da qualidade das previsões focando o conjunto de todos os produtos, percebeu-se claramente que a RBF apresentam melhores resultados se os centróides escolhidos forem pontos dentre os padrões de entrada do período de treinamento da RBF. Encontrou-se que 10% dos padrões de entrada é a quantidade suficiente de centróides para que a RBF retorne com bons resultados preditivos.

A proposta foi de realizar uma modificação no algoritmo de *k*-médias modificado, de forma a transformar os centróides resultantes do algoritmo de *k*-médias modificado apresentado, nos padrões, dentre os padrões de entrada, mais próximos a cada um desses centróides, alterando o resultado do algoritmo. Essa mudança proporcionou previsões de melhor acurácia para o conjunto de produtos, dando mais confiabilidade e segurança para a aplicação do sistema de reposição de produtos.

Percebeu-se também que para a previsão de séries temporais, como a sequência de tempo importa na explicação do fenômeno, não se deve utilizar os dados mais recentes para o conjunto de testes. Propõe-se neste trabalho, e justifica-se com os testes finais realizados, que se deve criar o conjunto de padrões de teste, escolhendo aqueles que estão entre os 80% dos padrões iniciais, respeitando a cronologia de tempo da série temporal. Isto se deve ao fato que as últimas informações das séries temporais devem influenciar mais o treinamento da RBF, melhorando assim a qualidade de previsão como um todo.

Fica ressaltado que esta última afirmação vale para séries temporais de vendas sem uma sazonalidade específica bem clara. No caso das séries temporais

em que a sazonalidade é evidente, então a previsão deve ser influenciada pelo período de sazonalidade conhecido e pelo período do qual se pretende prever. A utilização dos últimos 20% dos padrões no período de treinamento da RBF vale para séries temporais de vendas para produtos que não se consegue definir com clareza essas sazonalidades, os quais representam mais de 98% dos produtos de uma rede supermercadista.

A inovação deste trabalho no âmbito algorítmico foi o fato de encontrar sistematicamente uma configuração única, parâmetros da RBF com uma mudança inédita no algoritmo de escolha dos centróides, que possa minimizar os erros de previsão de todo o conjunto de produtos que necessitarão de reposição nas lojas.

Este trabalho pretende-se inovar na área de inteligência artificial, utilizando um algoritmo heurístico (RBF), para aprender sistematicamente e sem a interferência do tomador de decisão nos parâmetros, melhorando a acurácia geral das previsões de grandes quantidades de produtos. A única mudança necessária, a cada previsão de um novo produto, são os dados de entrada que a cada semana são atualizada, "retreinando" a RBF automaticamente e gerando novas previsões e limites de reposição.

A estratégia proposta foi implantada na empresa pesquisada, apresentando índices de ruptura de 0,5% a 0,8%, nos hipermercados, e entre 1,5% e 2% nos supermercados, lembrando que os índices de ruptura encontrados, por ocasião do início do trabalho eram, em média, de 12%.

O *mix* das lojas aumentou significativamente, representando um aumento considerável de vendas e do nível de serviço oferecido aos clientes. Houve um aumento de pedidos de reposição das lojas para o CD, porém, com quantidades menores e mais freqüentes. Os dias de cobertura foram definidos por classificação de giro dos produtos, distribuindo o carregamento dos caminhões de modo mais homogêneo entre todos os dias da semana que ocorre a reposição (de segunda-feira a sábado), tendo em média 40.000 caixas por dia.

O aumento do *mix* nas lojas, o aumento de pedidos de reposição em menores quantidades e com uma maior freqüência, o aumento de vendas e, principalmente, a diminuição do nível de ruptura, mostram que o planejamento estratégico de reposição com parâmetros flutuantes é altamente viável e recomendável. Verifica-se que, utilizando uma previsão de vendas mais confiável e estabelecendo limites de estoque mais assertivos, tem-se uma confiável ferramenta

de auxílio à tomada de decisão, uma vez que une métodos qualitativos de gestão de estoques e quantitativos com algoritmos confiáveis.

Sugere-se como continuidade da pesquisa, visando o desenvolvimento de trabalhos futuros, a avaliação do mesmo problema através de outros algoritmos clássicos, como os métodos de ARIMA de Box e Jenkins, a Regressão Logística e o *Support Vector Machine - Regression*.

Fica a sugestão do estudo do impacto no tempo computacional caso fossem alterados os parâmetros de RBF até que o erro de teste atingisse um valor limite pré-determinado ou selecionando o conjunto de parâmetros com menor erro de teste. Também, fica a sugestão de estudo desse impacto alterando-se e testando-se outros algoritmos de previsão. Encontrar um equilíbrio entre o número de testes computacionais e um valor de previsão aceitável é um trabalho que pode continuar a ser desenvolvido.

A discussão sobre prever um conjunto de séries temporais, com diferentes características, utilizando um ou mais algoritmos de previsão e o esforço computacional gasto, mesmo com a “revolução tecnológica” em que estamos, é um tópico a ser abordado em futuras investigações acadêmicas e operacionais. Questionar a necessidade de exaustivos testes computacionais alterando algoritmos e seus parâmetros (maior gasto de tempo computacional), em razão da diminuição do erro de teste (às vezes obtém-se um ganho irrelevante) é uma questão que fica para trabalhos futuros.

Também ficam para trabalhos futuros, outras mudanças nos parâmetros da RBF, com um estudo mais profundo sobre a dimensão dos campos receptivos, outras funções de ativação e até melhorias nos algoritmos de escolha dos centróides, por exemplo.

Sugere-se, ainda, o estudo e o impacto nos algoritmos das características de vendas dos produtos. Assim novas abordagens de classificação, utilizando outras informações, de forma a melhorar a similaridade de produtos e a identificação de algoritmos de previsão mais condizentes a cada grupo estabelecido.

Por fim, sugere-se que a metodologia aqui apresentada seja aplicada a outros problemas envolvendo a predição de séries temporais.

REFERÊNCIAS

- ACNIELSEN. **Ruptura: Causas e impactos na cadeia de abastecimento e no comportamento do consumidor**. Presentation held at ECR Brazil Conference, São Paulo, 2004.
- AKABAY, C. K.; WANG, G. C.S. **Autocorrelation: Problems and Solutions in Regression Modelling**. The Journal Business of Business Forecasting Methods and Systems. New York. Winter 94/95. v. 13, Issue 4, p 18-27. 1995
- ANDERSON, E. T., FITZSIMONS G. J., SIMESTER, D. **Measuring and Mitigating the Costs of Stockouts**, Management Science, Vol. 52, No. 11, pp. 1751–1763, 2006.
- ÂNGELO, C. F.; SIQUEIRA, J. P. L. **Avaliação das condições logísticas para a adoção do ECR nos supermercados brasileiros**. RAC-Revista de Administração Contemporânea. v.4, n.3, p. 89-106. Set./Dez. 2000.
- ATKINSON, A. C., KOOPMAN, S. J., SHEPHARD, N. **Detecting shocks: outliers and breaks in time series**. Journal of Econometrics, 80, p. 387-422. 1997.
- BALLOU, R. H. **Logística empresarial: transporte, administração de materiais e distribuição física**. 5ª ed. Porto Alegre: Bookman. 2006.
- BARAJAS, R. F. **Optimizando la disponibilidad de producto para el consumidor**. LOGYCA – Logística y Cadena de Valor. IAC Colômbia, 2004.
- BHARGAVA, H. K., DAEWON S., XU S. H. **Stockout Compensation: Joint Inventory and Price Optimization in Electronic Retailing**, Journal on Computing, Vol. 18, No. 2, pp. 255–266, 2006.
- BISHOP, R. **Neural Networks for Pattern Recognition**. Oxford University Press, USA. 1 ed. 504p. 1996.
- BOX, G. E. P. JENKINS, GM. **Time series Analysis, Forecasting and Control**, Holden-Day, San Francisco. 1976.
- BOWERSOX, D.J., CLOSS, D.J. **Logistical Management - The Integrated Supply Chain Process**, 1 ed, McGraw-Hill.1996.
- BOWERSOX, D.J., CLOSS, D.J., COOPER, M.B. **Gestão da Cadeia de Suprimentos e Logística**, Tradução da 2ª Edição, Ed. Elsevier, 2007.
- BUCHTALA, O., KLIMEK, M., SICK,B. **Evolutionary Optimization of Radial Basis Function Classifiers for Data Mining Applications**. IEEE Transactions on Systems, Man, and Cybernetics—part b: cybernetics, vol. 35, no. 5, october 2005
- CAMPO, K., GIJSBRECHTS E.L.S., NISOL P.. **Towards Understanding Consumer Response to Stockouts**. Journal of Retailing, Vol.76, No. 2, pp. 219–242, 2000.

CARSE, B., PIPE, A.G., FOGARTY, T.C., HILL, T. **Evolving radial basis function neural networks using a genetic algorithm**. IEEE International Conference on Evolutionary Computation, p. 300-305, 2005.

CHANG, F. J., LIANG, J. M., CHEN, Y. C. **Flood Forecasting Using Radial Basis Function Neural Networks**. IEEE transactions on systems, man, and cybernetics - part C: applications and reviews, vol. 31, n. 4, p. 530- 535, novembro, 2001

CHANG, F. J., CHEN, Y. C. **Estuary water-stage forecasting by using radial basis function neural network**. Journal of Hydrology, p.158 - 166, 2003.

CHEN, J. P. **Longitudinal and transverse response functions**. Ph.D. thesis. University of Virginia, 1991

CHEN, S., COWAN, C. F. N., GRANT, P. M. **Orthogonal least square learning algorithm for radial basis function networks**. IEEE Transactions on neural networks, vol. 2, n.2, março, 1991.

CHEN, S., HONG, X., HARRIS, C.J., HANZO, L. **Fully complex-valued radial basis function networks: Orthogonal least squares regression and classification**. Neurocomputing, vol. 71, p. 3421 – 3433, 2008.

CHOPRA, S. MEINDL, P. **Gestão da Cadeia de Suprimentos: Estratégia, Planejamento e operações**. 4ª Edição. São Paulo: Ed. Pearson Prentice Hall, 2010.

COELHO, L. S.; CANGIOLIERI Jr, O. **Rede neural de base radial aplicada em previsão de séries temporais: algoritmo e aplicação**. XX ENEGEP - Construindo competências para a manufatura internacional. 2000.

COELHO, L. S., SANTOS, A. A. P. **A RBF neural network model with GARCH errors: Application to electricity price forecasting**. Electric Power Systems Research 81 (2011) 74–83

CUNHA G.B., LUITGARDS-MOURA J. F., NAVES, E. L. M., ANDRADE A. O., PEREIRA A. A., MILAGRE S.T. **A utilização de uma rede neural artificial para previsão da incidência da malária no Município de Cantá, Estado de Roraima**. Revista da Sociedade Brasileira de Medicina Tropical 43(5):567-570, set-out, 2010.

DE LUCA, A. **Tercer estúdio de Faltantes de mercadería em gôndolas**. FMG III. Ahold. 16 de Setembro de 2004.

DIAS, G. J. C. **Planejamento estratégico de um centro de distribuição: uma aplicação de Redes Neurais Artificiais de funções de bases radiais para previsão de séries temporais**. Dissertação de Mestrado. Programa de Métodos Numéricos em Engenharia. Universidade Federal do Paraná. 2007.

DIAZ, C. A. P.; PIRES, S.R.I. **Variação da demanda ao longo da cadeia de suprimentos: o efeito da amplificação da demanda**. XXVIII ENEGEP - Redes produtivas para o desenvolvimento regional. Ouro Preto – MG, 21 a 24 de Outubro de 2003.

DU, J. D., HUANG, D. S., ZHANG, G. J., WANG, Z. F. **A novel full structure optimization algorithm for radial basis probabilistic neural networks.** Neurocomputing, v. 70, p. 592 - 596, 2006.

DU, H., ZHAN, N. **Time series prediction using evolving radial basis function networks with new encoding scheme.** Neurocomputing, v. 71, p. 1388–1400, 2007.

ECR BRASIL. Pricewaterhouse Coopers (Cood.). **Gerenciamento por Categorias: melhores práticas.** São Paulo: Associação ECR Brasil, 1998.

ECR BRASIL. Campanha para reduzir rupturas em R\$ 1 Bi. **4º Fascículo: Como Reabastecer as Gôndolas.** Revista Supermercado Moderno. Vol. 4. 2008. Acesso em 27 de outubro de 2009.
www.sm.com.br/publique/media/2008_smdownloads_guia_pratico_4.pdf

FALCO I., CIOPPA, A. D., IAZZETTA, A., NATALE, P. TARANTINO E. **Optimizing neural networks for time series prediction.** in Proc. 3rd On-Line World Conf. Soft Computing (WSC3). Advances in Soft Computing — Eng. Design and Manufacturing, R. Roy, T. Furuhashi, and P. K. Chawdhry, Eds, June 1998.

FERRARO, C. FOURNIER, F. **On Shelf Availability.** Unilever. CECRAL, 2004.

FIGUEIREDO, K. **A logística enxuta.** Centro de Estudos em Logística – COPPEAD/UFRJ. Rio de Janeiro, Out./2006.

FITZSIMONS, G. J. **Consumer Response to Stockouts,** Journal of Consumer Research, Vol. 27, September, pp. 249-266. Florida State University, 2000.

GHODS, L., KALANTAR, M. **Long-Term Peak Demand Forecasting by Using Radial Basis Function Neural Networks.** Iranian Journal of Electrical & Electronic Engineering, vol. 6, n. 3, Set. 2010.

GONZALEZ, J., ROJAS, I., ORTEGA, J., POMARES, H., FERNÁNDEZ, F. J., DÍAZ, A. F. **Multiobjective Evolutionary Optimization of the Size, Shape, and Position Parameters of Radial Basis Function Networks for Function Approximation.** IEEE Transactions on Neural Networks. V. 14, n. 6, Novembro 2006.

GRUEN, T. W., CORSTEN D. S., SUNDAR BHARADWAJ, S. **Retail Stockouts: A Worldwide Examination of Extent, Causes and Consumer Responses,** The Food Marketing Institute and CIES – The Food Business Forum, 2002.

GRUEN, T. W., CORSTEN, D. S. **A Comprehensive Guide To Retail Out-of-Stock Reduction In the Fast-Moving Consumer Goods Industry,** University of Colorado. USA and Business School Madrid, 2007.

GRUEN, T. W. **Retail Out-OF-Stocks: A worldwide examination of extent causes, and consumer responses (and some solutions).** RETECHLA - Retail Technologies for Latin America, 2007.

GUERRA, F. A., COELHO, L.S. **Multi-step ahead nonlinear identification of Lorenz's chaotic system using radial basis neural network with learning by clustering and particle swarm optimization**. Chaos, Solitons and Fractals, v. 35, p. 967–979, 2008.

HAMILTON, J. D. **Times series analysis**. Princeton University Press. Princeton, 1994.

HAYKIN, S. **Redes Neurais. Princípios e prática**. Porto Alegre, RS: Bookman, 2001.

HASSOUN, S. **Logic Synthesis and Verification**. Tufts University, Medford, Massachusetts, USA, 1995.

HONG, X., HARRIS, C. J. **Experimental design and models construction algorithm for radial basis function networks**. International Journal of Systems Science, vol. 34, n. 14-15, p. 733-745, 2003.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (**IBGE**), 2007. disponível em:
<http://www.ibge.gov.br/home/estatistica/indicadores/comercio/pmc/default.shtm>,
 recuperado em 10/11/09

JUNGES A.H., FONTANA D. C. **Modelo agrometeorológico-espectral de estimativa de rendimento de grãos de trigo no Rio Grande do Sul**. Revista CERES. Vol 58, n. 1, p. 9-16. Viçosa, 2011.

KARAYIANNIS, N. B., MI, G. W. **Growing radial basis neural networks: Merging supervised and unsupervised learning with network growth techniques**. IEEE Trans. Neural Networks, vol. 8, pp. 1492–1506, Nov. 1997.

KARAYIANNIS, N. B. **Reformulated radial basis neural networks trained by gradient descent**. IEEE Trans. Neural Networks, vol. 10, pp.657–671, May 1999.

KHAIRNAR, D.G., MERCHANT, S.N., DESAI, U.B. **Radial basis function neural network for pulse radar detection**. IET Radar Sonar Navigation, v.1, p. 8 – 17, 2007.

KUO, R.J., HU, T. L., CHEN, Z.Y. **Application of Radial Basis Function Neural Network for Sales Forecasting**. International Asia Conference on Informatics in Control, Automation and Robotics, 2009.

LAMBERT, D.M.; COOPER, M.C.; PAGH, J.D. **Supply chain management: implementation issues and research opportunities**. The International Journal of Logistics Management, v.9, nº2, 1998.

LANGARI, R., WANG, L., YEN, J. **Radial basis function networks, regression weights, and the expectation-maximization algorithm**. IEEE Trans. Syst. Man Cybern. A, vol. 27, pp. 613–623, Sept. 1997.

- LEE, C. C., CHIANG Y.C., SHIH C. Y., TSAI C. L. **Noisy time series prediction using M-estimator based robust radial basis function neural networks with growing and pruning techniques**. Expert Systems with Applications, v. 36, p. 4717 - 4724, 2009.
- LIN, W. M., GOW, H. J., TSAI, M. T. **An enhanced radial basis function network for short-term electricity price forecasting**. Applied Energy, v. 87, p. 3226 – 3234, 2010.
- LUCAS JR., H. C. **Tecnologia da informação: tomada de decisão estratégica para administradores**. Rio de Janeiro: LTC, 2006.
- MAILLARD, E. P., GUERLOT, D. **RBF neural network, basis functions and genetic algorithms**. Proc. 1997 IEEE Int. Conf. Neural Networks, vol. 4, pp. 2187–2190, 1997.
- MAKRIDAKIS, S., WHEELWRIGHT, S. C. McGEE, V. E. **Forecasting: methods and applicatinos**. John Wiley & Sons, New York, 1983.
- MENG, K., DONG, Z.Y., WONG, K.P. **Self-adaptive radial basis function neural network for short-term electricity price forecasting**. IET Generation. Transmission. Distribution, vol. 3, Iss. 4, p. 325 - 335, 2009.
- MILEVA-BOSKOSKA, B. **Comparison of Support Vector Machines and Radial Basis Function Models for Prediction of NO2 Concentration Levels**. 8th International PhD Workshop on Systems and Control a Young Generation Viewpoint, Balatonfüred, Hungria, 2007.
- MOODY, J.; DARKEN, C. **Neural Computation**, 1989.
- MOREIRA L. F. **Multicolinearidade em análise de regressão**. In: 12º Encontro Regional de Matemática Aplicada e Computacional, Foz do Iguaçu. Anais, Unioeste. p.61-75, 2008.
- MORETTIN P.A, TOLOI CMC. **Previsão de séries temporais**. 2ª. ed. São Paulo: Atual Editora. 1985.
- MUSAVI, M. T., AHMED, W. , CHAN, K. H., FARIS, K. B., HUMMELS, M. **On the training of radial basis function classifiers**. Neural Networks, vol. 5, no. 4, pp. 595–603, 1992.
- MONTGOMERY, D. C., JOHNSON, L. A. **Forecasting and time series analysis**. McGraw-Hill, New York, 1976.
- NOVAES, A. G. **Logística e Gerenciamento da Cadeia de Distribuição: Estratégia, Operação e Avaliação**. Editora Campus, Rio de Janeiro, Ed. Elsevier, 10ª reimpressão, 2007.

OLIVEIRA M. A., SIQUEIRA, J. O., BUENO U. **Um estudo comparativo quanto à eficiência de previsão de séries temporais utilizando redes neurais artificiais recorrentes (RTRL) e processos ARIMA-GARCH.** VII SEMEAD. Seminários em Administração FEA-USP, 2004.

OLIVEIRA, A. C. S. de, SOUZA, A. A. de, LACERDA, W. S., GONCALVES, L. R. **Aplicação de redes neurais artificiais na previsão da produção de álcool.** Ciência Agrotecnologia. ISSN 1413-7054, vol.34, n.2, pp. 279-284 . [online]. 2010

PASSARI, A. F. L. **Exploração de Dados Atomizados para Previsão de Vendas no Varejo Utilizando Redes Neurais.** Dissertação de Mestrado. Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo. 2003

PECKHAM, J. **The Consumer Speaks.** Journal of Marketing, vol. 27, October, pp. 21-26.1963.

PORTUGAL, M. S. **Neural networks versus time series: a forecasting exercise.** Revista Brasileira de Economia, 49 (4), p. 611-629, 1995.

PORTUGAL, M. S., FERNANDES, L. G. L. **Redes Neurais Artificiais e previsão de séries econômicas: Uma introdução.** Nova Economia, vol. 6, n. 4, p. 611-629, 1996.

POIRIER,C.C., REITER,S.E. **Supply chain optimization.** San Francisco: Berret-Koehler, 1996.

PROGRESSIVE GROCER **The Stockout Study: A Crusade Against Stockouts,** The National Association of Food Chains and A.C. Nielsen, Parts 1 and 2, pp. S1-S31, 1968.

RANAWEERA, D. K., HUBELE, N. F., PAPALEXOPOULOS, A. D. **Application of radial basis function neural network model for short-term load forecasting.** IEE Proceedings - Generation, Transmission and Distribution, vol. 142, n. 1, Janeiro, 1995.

REVISTA SUPER HIPER. (Associação Brasileira de Supermercados) **Ed. Maio de 2005.** disponível em: http://www.abrasnet.com.br/super/maio_2005_capa.asp, recuperado em 12/11/09.

REVISTA SUPER HIPER. (Associação Brasileira de Supermercados) **Ed. Novembro de 2008.** São Paulo, v. 62,n. 362, novembro de 2008.

RUMELHART, D. E., WEIGEND, S. A. **Predicting the future: a connectionist approach.** Stanford, 25, p. 737-744. 1990.

ROJAS, I., POMARES, H., GONZÁLEZ, J., ROS, E., SALMERÓN, M., ORTEGA, J., PRIETO, A. **A new radial basis function networks structure: Application to time series prediction.** In Proc. IEEE-INNS-ENNS Int. Joint Conf. Neural Networks, S. I. Amari, C. L. Giles, M. Gori, and V. Piuri, Eds, Como, Italy: IEEE Computer Society, vol. IV, pp. 449–454, July 2000a.

ROJAS, I., GONZÁLEZ, J., CAÑAS, A., DÍAZ, A., F. ROJAS, F. J., RODRIGUEZ, M. **Short-term prediction of chaotic time series by using RBF network with regression weights.** International Journal Neural Systems, vol. 10, no. 5, pp. 353–364, 2000b.

RUSSELL, S. J.; NORVIG, P. **Inteligência artificial: teoria e prática.** 2.ed. Rio de Janeiro: Campus, 2004.

SAHA, A.; KELLER, J. D.; MORGAN K. **Neural Information Processing Systems,** San Mateo, CA, 1990.

SCARPIN, C. T.; STEINER, M. T. A. **Proposal for a strategic planning for the replacement of products in stores based on sales forecast.** Pesquisa Operacional, ISSN 0101-7438. Aug. 2011, vol. 31, n.2, p. 351-571, 2011.

SCHARY, P. B., CHRISTOPHER M. **The Anatomy of a Stock-Out.** Journal of Retailing, Vol. 55, No. 2, pp. 59-70, 1979.

SILVA, I. N., SPATTI, D. H., FALUZINO, R. A. **Redes Neurais Artificiais:** para Engenharias e Ciências Aplicadas. São Paulo: Artliber, 2010.

SMITH, K. A.; GUPTA, J. N. D. **Neural networks in business: techniques and applications for the operations researcher.** Computers & Operations Research, p.1023-1044. Set. 2000.

SONG, S., YU, Z., CHEN, X. **A Novel Radial Basis Function Neural Network for Aproximation.** Internacional journal of Information Tecnology, v. 11, n.9, 2005.

TEITZ, M.B.;BART,P. **Heuristic Methods for Estimating the Generalized Vertex Median of a Weighted.** Operations Reserch, vol. 16, p. 955-961, 1968.

UYSAL, M. **The Effect of several parameters on radial function networks for time series prediction.** Journal of Applied Sciences – Asian Network for Scientific Information, v.6, p. 1608 – 1611, 2006.

VASCONCELLOS, L.H.R.; SAMPAIO, M.; PASTORE,R. **Logística de varejo: Uma análise sobre a questão da ruptura de estoque e suas causas no setor supermercadista paulista sob a ótica dos gestores do negócio.** Núcleo de Pesquisa e Publicação. Escola Superior de Propaganda e Marketing. São Paulo. Relatório de Pesquisa Dez./ 2007.

WAN, E.A. **Time series prediction by using a connectionist network with internal delay lines,** In Time Series Prediction: Forecasting the Future and Understanding the past. Addison –Wesley, pp.195-217, 1994.

WANG, M.; LAN, W. **Combined Forecast Process: Combining Scenario Analysis with the Technological Substitution Model.** Technological Forecasting & Social Change. v. 74, p. 357–378, 2007.

WANKE, P. F. **O impacto das características do negócio nas decisões logísticas e na organização do fluxo de produto: um estudo exploratório em seis setores econômicos.** RAC-Revista de Administração Contemporânea. v.7, n.3. Jul./Set. 2003.

WANKE, P. F. **Uma Revisão dos Principais Modelos de Regressão Múltipla para Previsão de Vendas de Postos de Combustíveis** In:Rio Oil and Gás Expo and Conference 2004. Rio de Janeiro, 2004.

WASSERMAN, P. D. **Neural computing: Theory and Practice.** Van Nostrand Reinhold, New York. 1989.

WHITE, H. **Artificial neural networks: Approximation and learning theory.** Blackwell Publishers, Oxford, 1992.

WHITEHEAD, B. A., CHOATE, T. D. **Cooperative-competitive genetic evolution of radial basis function centers with widths for time series prediction.** IEEE Trans. Neural Networks, vol.7, pp. 869–880, July 1996.

WOMACK, J. P.; JONES, D. T. **Lean Consumption.** Harvard Business Review, Mar 2005.

YAO X. **Evolving Artificial Neural Networks.** Proceedings of the IEEE, vol. 87, no. 9, september 1999

YEN, G. G., LU, H. **Hierarchical rank density genetic algorithm for radial-basis function neural network design.** In Proc. Congr. Evolutionary Computation (CEC), vol. 1, Honolulu, HI, pp. 25–30, 2002.

ZHAO, W. B., HUANG, D. S., DU, J. Y., WANG, L. M. **Genetic optimization of radial basis probabilistic neural networks.** International Journal of Pattern Recognition and Artificial Intelligence, vol. 18, n. 8, p. 1473 - 1499, 2004.

ZEMOURI, R., RACOCEANU, D., ZERHOUNI, N. **Recurrent radial basis function network for time-series prediction.** Engineering Applications of Artificial Intelligence, v.16, p. 453 – 463, 2003

ZINN, W., LIU, P.C. **Consumer Response to Retail Stockouts.** Journal of Business Logistics, Vol. 22, No. 1, pp. 49-71, 2001.

APÊNDICE

TRABALHOS CORRELATOS

Para a realização do presente trabalho se faz necessário o estudo de trabalhos correlatos em diversas áreas. Procura-se nesta seção criar uma seqüência lógica de apresentação dos trabalhos correlatos pesquisados para que se possa compreender a importância de conhecer o ambiente em que o principal problema tratado está inserido.

São apresentados trabalhos correlatos encontrados na literatura, em ordem cronológica, primeiramente sobre o tema da logística e seus principais aspectos, para se ter o contexto geral do problema e, em seguida, apresenta-se os trabalhos correlatos que estão relacionados diretamente a modelagem matemática e algoritmos utilizados para a obtenção da previsão de vendas. Estes trabalhos dizem respeito ao estudo de séries temporais; a previsão de séries temporais; os principais modelos estatísticos de previsão e trabalhos que utilizaram as Redes Neurais Artificiais como o algoritmo de previsão. Além disso, são citados trabalhos que fazem comparações entre diversos métodos de previsão de séries temporais e um levantamento da aplicação e estudo sobre as RBF.

LOGÍSTICA

A logística é o processo da cadeia de suprimentos que planeja, implementa e controla o fluxo e o estoque de bens e serviços e as informações relativas, do ponto de origem ao ponto de consumo, de maneira eficiente e eficaz, buscando a satisfação das necessidades do cliente. BALLOU (2006) ainda apresenta outra definição de logística empresarial, esta mais completa. Segundo ele, trata-se de uma área importante da administração, essencial no atendimento aos clientes e na estratégia competitiva da própria empresa. Entre as atividades aí incluídas estão: transporte, manutenção de estoques, processamento de pedidos, compras,

armazenagem, manuseio de materiais, embalagem, padrão de serviços aos clientes e programação da produção.

Ainda é comum observar certa confusão entre Gerenciamento da Cadeia de Suprimentos (GCS) e Logística. O fato é que a GCS envolve um escopo muito maior do que a Logística. Tradicionalmente, a Logística trata da movimentação e armazenagem de produtos. Isto é somente um “pedaço” da GCS. Em 1998, o Conselho de Gestão Logística definiu que a logística é um subconjunto do gerenciamento da cadeia de abastecimento e que os dois termos não são sinônimos.

Poirier e Reiter (1996) consideram a GCS um sistema que envolve todos os elementos de uma cadeia de produção, do fornecedor de matéria-prima até a entrega do produto (ou serviço) pelo comércio varejista (ou pela empresa prestadora de serviços) ao consumidor final, visando à otimização da cadeia de valores como um todo. Essa idéia é derivada da premissa segundo a qual a cooperação entre os membros da cadeia de valores reduzirão os riscos individuais e poderão, potencialmente, melhorar a eficiência do processo logístico, eliminando perdas e esforços desnecessários. O trabalho de Lambert *et al.* (1998) concentra-se na operacionalização do gerenciamento da cadeia de suprimento; ainda, faz estudos de caso em várias empresas e envolve vários membros das cadeias de abastecimento para ilustrar os conceitos descritos.

Com esse conceito de integração do GCS, as lojas tradicionais de comércio de varejo estão gradativamente perdendo espaço para as lojas de auto-serviços, segundo a revista Super Hiper (1996). Nas lojas tradicionais, a venda depende de atendimento, requerendo a presença de vendedor ou balconista, caracterizada pelo comércio de alcance local ou de vizinhança, como é o caso das padarias, armazéns e mercearias. Isto ocorre devido a facilidade de troca de informações na cadeia de suprimentos (ou cadeia de abastecimento) desse tipo de comércio e a facilidade de operações logísticas para o percurso completo do produto nesta cadeia de suprimentos.

O livro *Logistical Management*, escrito por autores renomados (BOWERSOX; CLOSS, 1996), destina-se a explorar toda a logística, transporte, material e modelos de gestão, bem como para o curso de logística eleitoral para as grandes empresas de *marketing*. O livro de Novaes (2007), 10ª edição, consolida o autor como um dos principais pesquisadores brasileiros nesta área, focando em sua

obra estudos de casos no Brasil, aborda temas sobre as decisões logísticas e explora em profundidade o problema dos transportes.

Outro conceito importante que envolve as operações logísticas e o funcionamento da cadeia de suprimentos é o *ECR*. *ECR* (*Efficient Consumer Response* / Resposta Eficiente ao Consumidor) é um movimento global, no qual empresas industriais e comerciais, juntamente com os demais integrantes da cadeia de abastecimento (operadores logísticos, bancos, fabricantes de equipamentos e veículos, empresas de informática, etc.) trabalham em conjunto na busca de padrões comuns e processos eficientes que permitam minimizar os custos e otimizar a produtividade em suas relações. A associação *ECR* Brasil atua como facilitadora do processo, agrega empresas interessadas, forma comitês, divulga informações e resultados, entre outras atividades a fim de qualificar as empresas e os profissionais.

Em 1998, a *ECR* Brasil publicou um artigo sobre o gerenciamento por categorias (GC), que é um processo de parceria entre varejista e fornecedor que consiste em definir categorias de produtos conforme as suas necessidades (ex: matinais, beleza, limpeza) e gerenciá-las como se fossem unidades estratégicas de negócios. Tem como objetivo aumentar as vendas e a lucratividade por meio de esforços para agregar maior valor ao consumidor final. Entretanto essa filosofia não define como realizar todas essas tarefas, qual é o melhor modo de atender o cliente e quais são os parâmetros ou algoritmos que as empresas devem implementar para criar essa rede de mercado.

O artigo de Ângelo e Siqueira (2000) possui dois objetivos distintos. O primeiro é o de identificar os requisitos necessários à implantação da filosofia do por parte dos supermercados. O segundo propósito é o de avaliar as condições logísticas atuais das principais redes brasileiras em termos da utilização das práticas propostas pelo *ECR*. Os autores concluem que o relacionamento dos supermercados com a indústria ainda é pouco expressivo. A principal razão apontada é a baixa utilização do *EDI* (*eletronic data interchange* / Troca de Informações por meio eletrônico).

O artigo apresentado por Wanke (2003) tem por objetivo avaliar as relações das características do produto, da operação e da demanda com as decisões logísticas de coordenação do fluxo de produtos acabados, alocação dos estoques e base para acionamento da fabricação. A principal conclusão da pesquisa aponta que não existe um conjunto homogêneo de características capaz de explicar as decisões

tomadas, o que sugere a necessidade de segmentar uma eventual estratégia logística com base nas características do negócio.

As empresas procuram desenvolver suas competências essenciais em seus processos de negócio. Segundo Womack e Jones (2005), as ferramentas e os conceitos do gerenciamento da qualidade total (*TQM – Total Quality Management*) e o *JIT* são comumente aplicados para o desenvolvimento de novos produtos e novas formas de gestão.

Além do conceito de *ECR* entre produtores e distribuidores as empresas, geralmente, incorporam primeiramente o *JIT* entre fornecedores e unidades de produção, e em seguida, o *TQM* aliado à gestão de relacionamento com clientes (*CRM - Customer relationship management*), para que assim, finalmente, tenha-se a arquitetura de satisfação global e risco controlado no GCS. Estas cadeias de suprimentos, com foco em objetivos semelhantes no nível corporativo, tentam, assim, criar uma valorização em todas as suas etapas e, com isso, fazer com que o consumo seja o menor possível, caracterizando, deste modo, o conceito de consumo enxuto (*Lean Consumption*).

A logística enxuta foi tema do trabalho de Figueiredo (2006) no qual enfatiza a melhoria contínua na cadeia de suprimentos. Afirma que a logística enxuta tem muitos desafios, mas conta também com uma série de aliados e ações a serem praticadas para alcançar seu objetivo. São eles: agilidade, sincronização, análise de processos com o objetivo de identificar onde se perde tempo e onde se acumulam estoques, colaboração com fornecedores e clientes para o planejamento da demanda. E também, investimentos em tecnologia de informação para monitorar veículos, controlar estoques e dispor de indicadores *on-line* para medir desempenhos e poder antecipar ações corretivas no rumo.

O livro “Tecnologia da Informação: Tomada de Decisão Estratégica para Administradores”, de Henry Lucas (2006), enfoca o conhecimento e as habilidades-chave de que o profissional de logística precisa para exercer um papel ativo na gestão da tecnologia e obter os máximos benefícios do investimento em Tecnologia da Informação.

Com o desenvolvimento da computação e o crescimento da necessidade de informações mais assertivas sobre os processos, possuir sistemas inteligentes, que sejam programados com algoritmos mais robustos, está se tornando uma necessidade cada vez mais prioritária no setor logístico.

A FALTA DE PRODUTOS NAS GÔNDOLAS

A falta de produtos nas gôndolas ou ruptura é um tema debatido no mercado varejista há muito tempo, Peckham (1963) é uma das primeiras referências encontradas que trata do assunto mais profundamente. Em seu artigo, discute a perda potencial de negócios, para fabricantes e lojas de varejo, provocada por rupturas e o nível de armazenamento de produtos. Em 1968, a Progressive Grocer realizou uma pesquisa sobre faltas de produtos em hipermercados. Sua principal contribuição foi identificar as diferentes respostas do consumidor para essas faltas. Este conjunto de atitudes é conhecido como o comportamento *SDL* (*Substitute, Delay and Leave* / substituir o item, adiar a compra ou sair da loja) dos consumidores em resposta à falta de estoque.

Schary e Christopher (1979) investigaram o efeito de longo prazo da ruptura, mediram a reação *SDL* e as variáveis relacionadas à imagem da loja, fidelidade à marca e variáveis demográficas. Concluíram que a ruptura por longo tempo é capaz de provocar perdas significativas de mercado. Já Campo *et al.* (2000) trata como os varejistas podem sofrer perdas importantes, como resultado de ações de empresas. Apresentam um modelo de reações *OOS* (*out-of-stocks* / ruptura) dentro de uma categoria de produto. Os resultados confirmam a lealdade do consumidor ao item em falta e fidelização à loja implicando em uma diminuição substancial na probabilidade troca do produto e armazenagem, respectivamente. Em contrapartida, quando existem alternativas aceitáveis, os consumidores ficam muito mais “inclinados” a escolher outro produto. Isso enfatiza a necessidade de tratar ambas as reações de ruptura com ações devidas a cada uma.

No artigo de Fitzsimons (2000) são executados quatro experimentos envolvendo faltas de produtos em um contexto de escolha do consumidor. Os resultados sugerem que a resposta do consumidor à falta de estoque é impulsionada em grande parte por dois fatores: o efeito da dificuldade de fazer uma escolha a partir de um conjunto de produtos e o grau de preferência pessoal com os produtos alternativos para escolha. Zinn e Liu (2001) investigaram em profundidade a influência de outras variáveis na tentativa de explicar a reação *SDL* do consumidor

frente à faltas. Concluíram que as variáveis situacionais como urgência e grau de planejamento (compra planejada ou compra por impulso) têm grande influência sobre a decisão do consumidor.

Gruen *et al.* (2002) apresentam um trabalho sobre o nível de ruptura encontrado em diversas regiões pelo mundo. O trabalho sugere que os varejistas deveriam ser cautelosos, porque os resultados da pesquisa mostram que cada vez mais os clientes das lojas mudam mais rapidamente de escolhas e podem nunca mais voltar ao produto original.

Em 2004, um série de trabalhos internacionais e nacionais fizeram um levantamento sobre os índices de ruptura encontrados nos supermercados de seus países e regiões, respectivamente. Ferraro e Fournier (2004) na empresa Unilever, De Luca (2004) na Argentina, o Departamento de *Ingenieria Industrial (DII)*, da *Universidad de Chile, Facultad de Ciencias Fisicas y Matematicas*, setembro de 2004, fizeram estudos sobre o setor de supermercados chilenos, Barajas (2004) na Colômbia e a empresa ACNielsen (2004) no Brasil fizeram pesquisas para identificar os níveis e as causas da ruptura. Os dados destas pesquisas já foram apresentados anteriormente, na seção 2.2.3 Níveis de Rupturas deste trabalho, onde destaca-se a pesquisa no mercado brasileiro.

Os objetivos da pesquisa realizada por ACNielsen (2004) eram, dentre outros, mensurar a taxa média de ruptura nas grandes cadeias, identificar suas principais causas, avaliar o comportamento do consumidor frente a ruptura e definir foco e ações prioritárias para solução do problema. Nesta pesquisa chegou-se a de que a ruptura de 8% é significativa e requer atenção e sugerem como recomendações o seguinte: a ruptura deve ser medida regularmente; é essencial a identificação de causas para gerar ações de correção; a seleção da metodologia deve ser feita criteriosamente e deve-se buscar soluções conjuntas entre Indústria e Varejo para alcançar resultados mais efetivos.

Atrasos na disponibilidade de produtos são comuns no comércio eletrônico, onde os varejistas, via *internet*, tentam gerir suas empresas com estoques muito baixos. Enquanto isto reduz os custos de inventário, o efeito negativo da falta de estoque é maior e reduz a demanda líquida para o produto. A análise feita no trabalho de Bhargava *et al.* (2006) é sobre o efeito de oferecer um preço mais baixo durante a indisponibilidade do produto para compensar o tempo de espera de um cliente. O preço mais baixo, segundo os autores, recaptura alguma demanda

perdida e tem um importante efeito sinérgico: a taxa de aumento das vendas leva à diminuição dos custos unitários para a realização de inventário e de produtos de ordenação.

Existe uma extensa literatura teórica para investigar as políticas de estoque ideal para os varejistas. No entanto, várias análises recentes têm reconhecido que esses modelos raramente são aplicados na prática. Uma explicação para a escassez de aplicações práticas é a dificuldade de medir como as rupturas afetam tanto a demanda atual como a futura. Neste contexto, Anderson *et al.* (2006) relatam os resultados de um teste de campo de grande escala que mede a curto e a longo prazo, o custo de oportunidade de uma indisponibilidade de produtos. Os resultados têm implicações importantes para os varejistas que consideram o uso de descontos como uma resposta à falta de estoque, uma vez que oferecer descontos para incentivar os clientes a comprar, ao invés de cancelar as suas compras, amplamente utilizado na prática, foi a menos rentável das respostas que foram avaliadas.

Vasconcellos, Sampaio e Pastore (2007) publicaram um relatório sobre a logística de varejo, analisando a questão da ruptura de estoque e suas causas no setor supermercadista paulista sob a ótica dos gestores do negócio. Neste trabalho é examinado, além do nível de incidência da ruptura, também suas principais causas e responsabilidades.

A pesquisa de Gruen e Corstein (2007), conduzido pela Universidade do Colorado e do *IE Business School de Madrid* e financiado pela *Procter & Gamble*, fornece um relatório abrangente, examinando os conhecimentos fundamentais, a medição de abordagens e estratégias utilizadas para reduzir as rupturas de estoques de varejo nos bens de consumo da indústria. Dando continuidade a sua pesquisa, Gruen, em maio de 2007, apresentou um trabalho no *Retail Technologies for Latin America*, onde fez um estudo detalhado sobre os níveis de ruptura dos principais mercados mundiais. O trabalho é concluído com sugestões para amenizar o problema da ruptura, entre elas, medir e avaliar constantemente o nível de ruptura, identificar as causas, aplicar e incrementar as soluções encontradas continuamente observando a situação em que o supermercado se encontra.

Quando se tenta entender a ruptura, percebe-se que uma alternativa viável e possível é a melhoria no sistema de previsão de vendas ou previsão de demanda dos produtos. Os valores de venda, com o passar dos tempos, forma uma série

temporal histórica. O estudo dessas séries temporais e os modelos para realizar uma previsão adequada, baseada no histórico de vendas, é uma das alternativas mais aplicadas no mercado. Ao se compreender a série temporal formada pelo histórico de vendas podem-se aplicar métodos qualitativos e quantitativos de previsão e assim melhorar o sistema de reposição de estoque e diminuir a ruptura. Portanto, estudar as séries temporais já formadas é um passo essencial para ajustar o sistema de reposição.

PREVISÃO DE SÉRIES TEMPORAIS APLICADAS A GESTÃO DE ESTOQUES

A última década trouxe mudanças dramáticas na maneira como os pesquisadores analisam séries temporais econômicas e financeiras. O livro de Hamilton (1994) sintetiza os avanços recentes e os torna acessíveis a estudantes e pesquisadores iniciantes. James Hamilton traz em seu livro tratamentos adequados e inovações importantes na análise séries temporais, como auto-regressão vetorial, Método dos Momentos Generalizados, as consequências econômicas e estatísticas e os modelos da série não-linear do tempo. Além disso, ele apresenta ferramentas básicas para análise de sistemas dinâmicos (incluindo representações lineares, funções de auto-covariância, análise espectral e o filtro de Kalman) de uma forma que integra teoria econômica com as dificuldades práticas de análise e interpretação dos dados do mundo real.

A existência de observações discordantes com as restantes é de relativamente fácil determinação em amostras univariadas, em uma série temporal. Algumas vezes, por observação dos valores que constituem a amostra ou pela análise de alguns gráficos, é fácil identificar as observações que se afastam da maioria. Em outros casos, é necessária a aplicação de técnicas mais sofisticadas. Em ambos os casos, esta análise prévia tem de ser seguida de testes apropriados para confirmar as suspeitas de existência de observações *outliers* (elementos que não obedecem a um padrão do conjunto de dados ao qual eles pertencem).

Um procedimento utilizado é a intervenção simples em que um parâmetro extra é adicionado para a média da observação em questão. Os modelos de série

temporais contêm mais de uma variação (ATKINSON; KOOPMAN e SHEPHARD, 1997), o efeito da intervenção é medida pela mudança de variações das variáveis individuais. Em seu artigo de estes pesquisadores estudam o efeito sobre os parâmetros estimados para se fazer a intervenção ao longo da série temporal. Os problemas computacionais envolvidos são superados pelo uso de estatísticas de filtragem e suavização. A interpretação do tempo, resultando em parcelas da série de diagnósticos, é auxiliado por programas de simulação.

A previsão de séries temporais e suas aplicações tornaram-se cada vez mais importante em vários campos de pesquisa, tais como negócios, economia, engenharia, medicina, ciências sociais, política e outros. Desde que Box e Jenkins (1976) publicaram o livro *Time Series Analysis: Forecasting and Control*, um grande número de livros e um vasto número de trabalhos de previsão de séries temporais têm sido publicados nesta área.

O livro de Montgomery e Johnson (1976) tem por objetivo destilar e integrar esses resultados através de metodologias coesas e compreensíveis, e de proporcionar uma abordagem simplificada para análise de séries temporais e previsão. O uso de computadores e *softwares* é essencial em qualquer análise quantitativa moderna, mais ainda, na análise de séries temporais, onde algoritmos complexos e extensos cálculos são muitas vezes necessários. Com a velocidade e capacidade dos computadores modernos, em muitas situações é preferível escolher uma metodologia com cálculos mais complexos, porém que simplifica os meios de realizar uma análise, mesmo que seja em detrimento do tempo computacional.

Já o livro de Makridakis *et al.* (1983) é destinado para os problemas práticos de previsão, a cobertura abrangente de modelos estatísticos e como implementá-los na prática dentro de um ambiente empresarial da época, incluindo os desenvolvimentos de modelos na previsão de séries temporais. Enfatiza métodos gráficos e os utiliza para ajudar a compreender as análises. A perspectiva do livro é que a previsão é muito mais do que os modelos de ajuste de dados históricos. Segundo os autores, explicar o passado é importante, mas não é o suficiente para prever com precisão o futuro.

A previsão da demanda é uma etapa crítica para todos os membros de uma cadeia de suprimentos devido à complexidade e incertezas intrínsecas a suas atividades. Entre os principais efeitos indesejáveis, destaca-se o fenômeno de

amplificação da demanda (*bullwhip effect*) o qual provoca a variação da demanda ao longo de toda a cadeia.

As previsões podem ser melhoradas através da combinação de previsões distintas obtidas por métodos diferentes (WANG e LAN, 2007). A natureza complementar da análise de cenários e modelos de substituição tecnológica significa que a combinação de dois métodos pode obter melhores previsões. A análise de cenários tem a força de lidar com o futuro incerto, enquanto os modelos baseados nos dados para realizar as previsões são baseados em parâmetros quantificáveis.

Com seu estudo, Wang e Lan (2007) propõem, assim, um processo para combinar a análise de cenários com o modelo de substituição tecnológica para discutir a evolução da nova geração tecnológica. O processo proposto não só tem os pontos fortes da análise de cenários, mas também contém funcionalidades que carece de análise de cenários, incluindo a previsão da evolução anual para os próximos anos, considerando o desenvolvimento da tecnologia e previsão de substituição de tecnologias antigas. O estudo utiliza a previsão de participação em um mercado de Fibra de Taiwan nos próximos 10 anos como um exemplo que ilustra o processo proposto de previsão.

A revista Supermercado, edição de outubro de 2009, traz um artigo publicado pela ECR Brasil que diz que é preciso que se calcule as quantidades de produtos expostas em função de seu tamanho, porte e giro, e que os parâmetros sugeridos sejam avaliados regularmente, uma vez que, em geral, os *softwares* trabalham apenas com médias. Caso contrário, poderão ocorrer variações importantes ao longo do tempo (como vendas concentradas em determinados dias ou horários) sendo preciso calcular (via sistema) as quantidades de produtos vendidas por dia (ou período de tempo) e os tempos de entrega médios de cada fornecedor.

Também é necessário, segundo o artigo, calcular quantos dias de vendas comportam os estoques disponíveis, determinando a data e a quantidade de produtos a ser comprada. Para que o sistema funcione corretamente, é necessário que os registros de vendas, níveis de serviço e prazos envolvidos com cada operação sejam corretos e confiáveis. Itens sazonais ou promocionais, cuja previsibilidade de demanda e de entrega, em geral, sofrem grande variação, exigem cuidado especial. Assim, a ECR Brasil acredita que se deve ter controles de estoques de retaguarda separados dos da gôndola, com registros de entradas e

saídas independentes, de modo a saber exatamente onde estão os produtos a cada momento.

MODELOS DE PREVISÃO DE SÉRIES TEMPORAIS

Após analisar a estrutura das séries temporais é necessário encontrar e ajustar o modelo de previsão condizente, com o objetivo de melhorar a acuracidade do modelo. A primeira edição de “Inteligência Artificial: uma abordagem moderna” se tornou um clássico na literatura sobre Inteligência Artificial (IA). O livro de Russel e Norvig (2004) possui uma quantidade significativa de material, abrangendo áreas como: satisfação de restrições, inferência proposicional rápida, grafos de planejamento, agentes de inter-redes, inferência probabilística exata, técnicas de integração de Monte Carlo via cadeias de Markov, filtros de Kalman, métodos de aprendizado harmonioso, aprendizado estatístico, modelos probabilísticos de linguagens naturais, robótica probabilística e aspectos éticos da IA.

Outro livro que trata de análise de séries temporais é o de Wasserman (1989), no qual ele explica claramente para não-especialistas os principais algoritmos e desmistifica a rigorosa matemática envolvidas em Redes Neurais Artificiais (RNA). Usa um passo-a-passo para a implementação paradigmas comumente utilizados. As RNA passam a ser uma técnica explorada para a previsão de série temporais.

A previsão de demanda futura é essencial para o planejamento das atividades e decisões dentro da cadeia de suprimentos (CHOPRA e MEIDL, 2010). Os métodos para se realizar essa tarefa vão desde técnicas estatística simples, como as médias móveis até algoritmos mais robustos como o *Support Vector Machine* e as RBF. A seguir são apresentados trabalhos que aplicam diferentes técnicas para a previsão de séries temporais.

Técnica de Redes Neurais Artificiais

De acordo com Rumelhart (1990), que apresenta um modelo conexionista, baseado em RNA, para a previsão de dados, este modelo pode ser descrito por seis elementos principais:

1. Um conjunto de unidades de processamento;
2. Um estado de ativação;
3. Uma função saída;
4. Um padrão de interconexão;
5. Uma regra de propagação;
6. Uma regra de ativação;

Com isso, segundo Rumelhart (1990), o último componente de RNA é o ambiente onde a rede deve funcionar. É necessário especificar a natureza do ambiente, estabelecendo os possíveis padrões de entrada e saída. Em alguns modelos, por exemplo, na Distribuição de Processamento Paralelo (*PDP - Parallel Distributed Processing*) aplicado nas RNA utilizadas por Rumelhart, o ambiente é representado como uma função estocástica que varia ao longo do tempo sobre um espaço de padrões de entrada.

Geralmente, o ambiente é caracterizado como uma distribuição de probabilidade estável sobre um conjunto de padrões de entrada. Esta distribuição pode ser independente, ou não, de entradas ou de respostas passadas do ambiente. Outro problema enfrentado pela retropropagação (algoritmo *backpropagation*) é a quebra de simetria, ou seja, se os pesos das RNA utilizadas por Rumelhart começam todos com o mesmo valor e se a solução só pode ser alcançada com pesos diferentes, podendo, assim, o sistema não aprender.

De maneira geral, as RNA são modelos que relacionam dados de entrada com suas respectivas saídas. A partir da observação de exemplos e seu constante treinamento, obtém-se uma matriz de pesos os quais, por sua vez, representam as ligações entre os neurônios de entrada e saída, imitando o que ocorre nas interconexões entre as células nervosas do cérebro humano. A grande vantagem do uso das RNA relaciona-se com a adaptabilidade, que permite seu refinamento e minimização dos erros de previsão.

O processo de refinamento dos resultados, mediante o estudo dos erros e envio destes para o início do ciclo é conhecido como *feedforward backpropagation*. O *feedforward backpropagation* é um algoritmo tradicionalmente usado, que utiliza técnicas de otimização mediante gradiente descendente para o ajuste dos pesos entre conexões. Dessa forma, segue em direção a um ponto de mínimo na curva da superfície de erros.

White (1992) considera o problema de aprendizagem de RNA a partir de amostras e discute sobre como obter o tamanho da amostra que é suficiente para a obtenção da função estocástica de aproximação quase ótima. Em relação a função de ativação, White mostra que menos parâmetros quadráticos é quase ideal para o problema de previsão com RNA. Estas têm sido bastante empregadas na predição de valores e identificação de séries temporais (Wan,1994). A rede neural MLP (*Multilayer Perceptron*) é a mais utilizada dentre as RNA existentes, apesar de usar em sua maioria um mapeamento estático de entrada-saída.

O livro de Haykin (2001) foi concebido como um manual para um nível superior ou pós-graduação de RNA em ciência da computação, física, ou nos departamentos de engenharia. O autor apresenta claramente as equações e provas matemáticas, todas referenciadas, permitindo a oportunidade de rever as equações na obra original. A intercalação de teoria e discussão é uma característica que facilita a compreensão da usabilidade das RNA, onde a definição introdutória de uma rede neural é seguido por uma visão geral das arquiteturas das RNA.

Para auxiliar nos processos logísticos de reposição de produtos, a análise de séries temporais vem sendo um tema bastante abordado neste contexto. Já em 1996, Fernandes *et al.* utilizam a previsão de séries temporais através de um algoritmo de RNA, dando destaque as suas características estatísticas. O objetivo central do artigo de Portugal e Fernandes (1996) é introduzir e difundir um novo método de previsão de séries temporais econômicas. Esta modelagem consiste na criação de RNA nas séries econômicas. O cérebro humano é extremamente eficaz no reconhecimento de padrões e regularidades, sendo ainda capaz de generalizar com base no conhecimento acumulado. As RNA incorporam estas qualidades do cérebro sendo, portanto, capazes de realizar previsões. Características particulares de uma série de tempo, tais como: sazonalidade, tendência e ciclo podem ser aprendidas por uma RNA, possibilitando, assim, a realização de previsões.

No trabalho de Falco *et al.* (1998) é investigada a concepção eficaz de um modelo de RNA adequado para previsão de séries temporais com base em uma abordagem evolutiva. Utilizam os algoritmos genéticos para escolher a concepção de uma arquitetura de rede neural e a escolha do melhor método de aprendizagem. A principal motivação para a análise de séries temporais é o de fornecer uma previsão quando o modelo matemático de um fenômeno é desconhecido ou incompleto.

A evolução de algoritmos pode ser introduzida nas RNA em muitos níveis diferentes. Segundo Yao (1999), a evolução dos algoritmos fornece uma abordagem global para a formação dos pesos, especialmente quando a informação do gradiente da função erro é difícil ou caro de se obter. Neste mesmo trabalho, Yao afirma que a evolução simultânea da arquitetura da RNA e pesos de conexão geralmente produzem melhores resultados.

O artigo de Smith e Gupta (2000) apresenta uma visão geral dos tipos diferentes de modelos de RNA que são aplicáveis ao resolver problemas de negócios e discutem o papel das RNA como uma ferramenta moderna de apoio a gestão nas operações. Segundo os autores, as RNA estão se tornando cada vez mais populares no mundo dos negócios e muitas organizações estão investindo em RNA e mineração de dados para soluções de problemas que tradicionalmente têm caído sob a responsabilidade das equipes de pesquisa e desenvolvimento das empresas. A série temporal de vendas é muito sensível a qualquer fator mercadológico, fazendo com que um método mais robusto deva ser utilizado para a obtenção na previsão de vendas.

Comparações entre Métodos de Previsão

Com o intuito de melhorar os métodos de previsão de séries temporais, muitos trabalhos passaram a comparar dois ou mais métodos de previsão e tentar assim encontrar uma que forneça melhores resultados de previsão, gerando menores erros. O artigo de Portugal (1995) apresenta um exercício empírico de previsão econômica através de métodos tradicionais da análise de séries temporais,

como ARIMA, modelos de decomposição em componentes não observáveis (UCM) e RNA.

Portugal utiliza os dados brutos mensais da produção industrial para o estado do Rio Grande do Sul (Brasil) para realizar uma comparação e avaliar o desempenho relativo aos diferentes métodos de previsão. Os resultados mostraram que a RNA obtém uma previsão mais precisa do que os modelos ARIMA, mas a comparação com UCM não é tão simples. A UCM encontra uma previsão melhor que a previsão da RNA, mas o desempenho da RNA para horizontes maiores mostra previsões que, especialmente depois que uma metodologia adequada de modelagem foi estabelecida, pode ser uma ferramenta valiosa a previsão econômica.

Oliveira *et al.* (2004) apresentam um estudo comparativo quanto a eficiência de previsão de séries temporais utilizando processos ARIMA-GARCH e RNA treinadas com o algoritmo de aprendizagem recorrente em tempo real (RTRL – real time recurrent learning). Os Autores afirmam que tanto a modelagem usando RNA como os processos ARIMA-GARCH exigem a transformação dos dados da série original e verificam que as previsões das redes neurais tiveram desempenho superior quando comparadas aos resultados dos modelos econométricos tradicionais.

OLIVEIRA, *et al.* (2010) aplicaram as RNA para problema de previsão da produção de álcool com os dados de 2006. Os autores compararam os resultados das RNA com um trabalho que realizou a previsão desta mesma série com o método SARIMA (1, 0, 0) e (0, 1, 1) com intervenção. Os resultados indicaram que as RNA resultaram menor erro médio quadrático e erro médio percentual absoluto, obtendo assim, segundo os autores, melhores resultados de previsão do que o método SARIMA.

O objetivo do estudo de Cunha *et al.* (2010) foi investigar viabilidade de um modelo baseado em RNA para previsões séries temporais epidemiológicas. Os resultados obtidos pela RNA através dos três períodos, curto, médio e longo, mostraram-se adequados para o sistema de previsão de incidência da malária. Os Autores afirmam que as redes neurais apresentaram um maior poder de previsão ao modelo de regressão logística, diante dos dados da série histórica da malária no Município de Cantá, Estado de Roraima. Os erros quadráticos médios (EQM) obtidos através das RNA foram bem menores que as obtidas pelo método de regressão

exponencial mostrando a capacidade de aprendizagem e previsão de uma RNA, baseado em séries temporais epidemiológicas

Redes Neurais Artificiais de Funções de Bases Radiais

Dentre as variações das RNA, em relação a arquitetura e concepção, destaca-se para previsão de séries temporais as Redes Neurais Artificiais de funções de bases radiais (RBF). O uso da RBF é bastante difundido para esse objetivo e vem sendo alvo de pesquisas para seu aprimoramento e desenvolvimento de modo a encontrar um método com melhores índices de acerto de previsões.

Chen *et al.* (1991) foram praticamente primeiros na utilização de mínimos quadrados entre a camada oculta e a camada de saída. A seleção dos centróides foi de forma aleatória, sendo que os resultados não foram satisfatórios em algumas instâncias. Os autores afirmam que a aprendizagem das duas etapas da RBF, a não supervisionada seguida da supervisionada, a torna uma poderosa ferramenta para classificação e previsão de séries temporais.

Uma abordagem para a implementação da RBF é apresentada e aplicada a uma rede da arquitetura adequada no artigo de Musavi *et al.* (1992). O artigo explora uma metodologia para estimar os parâmetros da função kernel e como a quantidade de nós da RBF pode ser reduzida sem afetar significativamente o erro de formação geral. Aborda também os problemas enfrentados por esta técnica que tem sido demonstrada como superior aos algoritmos de treinamento mais tradicionais, devido a velocidade de processamento e de solução de padrões não-lineares. A solução proposta pelos pesquisadores torna a RBF um método mais eficiente para a interpolação e para a classificação.

A previsão de consumo de carga elétrica, com objetivo de dar mais segurança e economia ao sistema elétrico é o tema de trabalho de Ranaweera *et al.* (1995). Os autores utilizam a RBF e a RNA tradicional (com o algoritmo de treinamento *backpropagation*) e chegam a resultados mais satisfatórios de previsibilidade com a RBF. Neste trabalho a escolha dos centróides são definidos através do algoritmo das k-médias.

Uma Rede Neural de funções de base radial pode ser desenvolvida de forma híbrida para encontrar os centros da RBF, sendo desenvolvida por uma técnica cooperativa-competitiva de algoritmo genético (AG). Em 1995, Carse *et al.* (2005) utilizam o algoritmo genético para definir o número de centróides e o tamanho do raio de atuação dos mesmos. O trabalho de Whitehead e Choate (1996) foca nesse modelo híbrido, estudando como um conjunto de seqüências genéticas de uma geração do algoritmo genético pode representar uma RBF, e não uma população de redes concorrentes.

Langari *et al.* (1997) propõem uma RBF em que os pesos de regressão são usadas para substituir o peso constante na camada de saída. É mostrado que a RBF pode reduzir o número de neurônios na camada escondida significativamente, sendo que o desempenho superior da RBF é ilustrado por simulações computacionais.

Maillard e Gueriot (1997) observaram que quando as RBF são utilizadas em uma aplicação específica, os desempenhos dependem do número de neurônios e da distribuição dos neurônios na camada escondida e na camada de entrada. Geralmente, a RBF quando aplicada a uma arquitetura pré-determinada, ou é insuficiente ou não gera bons resultados. Os Autores discutem sobre as aprendizagem das RBF através de algoritmos genéticos, quando aplicadas a previsão de séries temporais caóticas. Os centróides da RBF na camada escondida são codificados em um cromossomo do algoritmo genético. Mostram que as funções de base radial também são codificados como um parâmetro dos neurônios para proporcionar um nível adicional de liberdade, resultando em uma menor arquitetura da RBF ideal. Uma pseudo-inversão (método da pseudo-inversa) da matriz fornece os pesos entre a camada escondida e a camada de saída e evita que a solução tenha convergência para um mínimo local.

O artigo de Karayiannis e Mi (1997) propõe a construção e a formação de um modelo de RBF. A proposta de rede neural com função de crescimento de base radial (GRBF) começa com um pequeno número de protótipos, que determinam a localização das funções de base radial. No processo de formação, a GRBF seleciona alguns nós como centróides em cada ciclo de crescimento. Dois critérios de seleção são propostos para determinar quais os centróides de cada ciclo de crescimento. No híbrido é proposto um esquema de aprendizagem fornecendo uma estrutura para a integração dos algoritmos existentes na formação das GRBF.

Estes incluem algoritmos para agrupamentos não supervisionados e

aprendizagem de quantificação vetorial, bem como algoritmos de aprendizado para a formação da única camada linear das Redes Neurais. Um esquema de aprendizado supervisionado baseado na variância condicional para minimização de classes localizadas também é proposto e testado. GRBF são avaliados e testados em uma variedade de conjuntos de dados com resultados muito satisfatórios.

O trabalho de Karayiannis (1999) apresenta uma abordagem axiomática de construção das RBF. Esta abordagem resulta em uma ampla variedade de modelos RBF admissíveis, incluindo as que utilizam funções gaussianas. A forma da RBF é determinada por uma função geradora. Novos modelos de RBF podem ser desenvolvidos de acordo com a abordagem proposta pela seleção geradora de funções que não sejam exponenciais, que usam a função gaussiana. Também em 1999, Chen et al. explora novamente a idéia de utilizar o algoritmo genético para definir os parâmetros da RBF e utiliza o método dos mínimos quadrados na segunda parte do treinamento, a supervisionada.

A configuração e aplicação de RBF para o procedimento de previsão de séries temporais é o tema principal abordado por Coelho e Canciglieri (2000). A RBF é avaliada em dois estudos de casos: na previsão da concentração de dióxido de carbono dos dados da fornalha de gás de Box e Jenkins e a previsão da equação diferencial de Mackey-Glass que descreve um sistema de controle fisiológico. As simulações tratam os procedimentos de estimação e validação do modelo neural. Os resultados indicam que o modelo neural proposto é atrativo para aplicações em identificação de sistemas complexos, aplicações financeiras e sistemas de informação. A RBF demonstrou vantagens devido a capacidade de aproximação de funções não-lineares, rapidez e eficiência do aprendizado, possibilitando a obtenção de resultados precisos. Entretanto, segundo os autores, necessita-se de estudos mais aprofundados quanto a aspectos de aprimoramento das capacidades de interpolação, generalização e aprendizado da RBF para a previsão de séries temporais.

Os artigos de Rojas *et al.* (2000a e 2000b) descrevem uma nova estrutura para criar uma RBF. Esta nova estrutura tem 4 características principais: em primeiro lugar, a arquitetura de rede especial RBF usa pesos de regressão para substituir os pesos constantes normalmente utilizados. A segunda característica é a normalização da ativação de neurônios ocultos (média ponderada) antes de agregar as ativações, que, como observado por vários autores, produz melhores resultados

do que a arquitetura clássica soma ponderada. O terceiro aspecto é que um novo tipo de função não-linear é proposta: a função pseudo-gaussiana (PGBF). Com isso, a rede neural obtém ganhos de flexibilidade, os neurônios possuem um campo de ativação que não tem necessariamente de ser simétrico em relação ao centro ou a localização do neurônio na camada de entrada. Além desta nova estrutura, Rojas *et al.* propõem como a quarta e última característica, um algoritmo sequencial de aprendizagem, que é capaz de se adaptar a estrutura da rede, com isso, é possível criar novas unidades escondidas e também de detectar e remover unidades inativas.

Em outro artigo, Rojas *et al.* (2000) apresentam uma proposta de construção e formação de uma RBF para previsões de curto prazo. A estrutura das funções gaussianas é modificada usando uma função pseudo-gaussiana, no qual dois parâmetros sigma de dimensionamento são introduzidos, o que elimina a restrição de simetria e fornece os neurônios na camada oculta com uma maior flexibilidade no que diz respeito à função de aproximação. O desempenho superior da técnica proposta sobre o sistema RBF padrão é justificado com testes em problemas de previsão de curto prazo de séries temporais caóticas.

A utilização da RBF para prever as cheias causadas pela vazão das chuvas foi o tema do trabalho de Chang *et al.* 2001. A arquitetura da RBF desenvolvida neste trabalho foi, para o treinamento não supervisionado, o algoritmo de lógica fuzzy min-máx e, para o treinamento supervisionado a regressão linear múltipla. Avantageira descrita pelos autores na aplicação do algoritmo fuzzy min-máx é a determinação automática e dinâmica dos centróides e campos receptivos. Estes mesmo autores publicaram outro artigo com a mesma concepção fuzzy mín-max, porém para prever a demanda de água em uma estação (CHANG e CHEN, 2003).

Um algoritmo genético com o objetivo de criar uma arquitetura para uma RBF é apresentado por Yen e Lu (2002). Neste trabalho, o autor apresenta a idéia de criação de um ranking hierárquico de densidade do algoritmo genético (HRDGA) o qual é usado para topologia de evolução da rede neural e seus parâmetros. Além disso, o fitness do AG é utilizado para otimizar o desempenho e a topologia da rede neural e para lidar com o conflito entre a formação, desempenho e complexidade da rede. Em vez de produzir uma única rede neural ideal, o HRDGA fornece um conjunto de Redes Neurais perto do ideal para os tomadores de decisão para que eles possam ter mais flexibilidade para a decisão final com base em suas preferências. As RBF concebidas pelo algoritmo proposto prova ser competitivas, ou

mesmo superior, a RBF para funções de Mackey-Glass na previsão de séries temporais caóticas. O modelo desenvolvido mostrou-se robusto e apresentou resultados otimizados em relação

Em 2003, Hong e Harris, propuseram uma alternativa para escolher os centróides e a dimensão do campo receptivo. Os Autores utilizaram a matriz de covariância dos dados de entrada e os autovalores para determinar a arquitetura da RBF, sendo desenvolvida uma função de custos através do processo de ortogonalização de matrizes. Zemouri *et al.* (2003) propões em seu trabalho uma rede recorrente para a RBF, utilizando a função de ativação Gaussiana, no estágio supervisionado, criou uma realimentação da informação melhorando assim o desempenho de previsão da RBF.

Zhao *et al.* (2004) desenvolve um algoritmo genético probabilístico para definição dos centróides da camada intermediária da RBF. O autor compara seus resultados com o algoritmo de k-médias modificado e um algoritmo recursivo de mínimos quadrados e chega a conclusão de que sua proposta obtem uma estrutura mais parcimoniosa em relação aos erros de previsão do que os outros dois métodos testados.

O artigo de Buchtala, Klimek e Sick (2005) descreve um algoritmo evolutivo que executa a função de seleção simultânea do modelo para classificadores de função de base radial. A fim de reduzir o esforço de otimização, várias técnicas são integradas para acelerar e melhorar os algoritmos evolutivos significativamente: de formação híbrida de Redes Neurais RBF, avaliação preguiçosa, entre outras. A viabilidade e os benefícios da abordagem são demonstrados por meio de quatro problemas de mineração de dados, detecção de intrusões em redes de informática, verificação de assinatura biométrica, para aquisição de clientes com métodos de marketing e otimização de processos na produção da indústria química. Nos algoritmos evolutivos baseado em técnicas de otimização com funções de bases radiais o tempo é reduzido em até 99%, enquanto as taxas de erro são reduzidas em até 86%, dependendo da aplicação.

Duas dificuldades estão envolvidas com a RBF tradicional: a configuração inicial de uma rede RBF que precisa ser determinada por um ensaio e certo método de erro e a degradação que o desempenho sofre quando a localização pretendida dos centróides não é adequada. O artigo de Song, Yu e Chen (2005) propõe alternativas para superar estas dificuldades. A nova função de base radial é usada

na camada oculta, onde o número de nós é determinado automaticamente pelo teorema da amostragem de Shannon. O algoritmo de aprendizagem correspondente geralmente leva muito menos tempo de aproximação com uma configuração de parâmetros otimizados. As localizações dos centróides da RBF são fixas. Resultados experimentais têm demonstrado que as redes RBF construídas pelo método proposto no artigo de Song, Yu e Chen têm um menor número de nós, uma velocidade mais rápida de aprendizagem e um menor erro de aproximação do que as redes produzidas por outros métodos.

Dias (2006) utiliza 7 (sete) séries temporais reais, que representa a demanda dos produtos alimentícios de um CD de uma empresa brasileira, com o objetivo de ajustar o melhor modelo para que as previsões sejam feitas a curto e a longo prazo, diminuindo assim incerteza no planejamento estratégico da empresa. O trabalho contempla estudos de previsões de series temporais através das RBF e compara seus resultados, com as previsões dos modelos ajustados através da Metodologia Box & Jenkins. Para efeito de comparação dos dois métodos Dias (2006) utiliza a medida do RMSE (Raiz do Erro Quadrático Médio). Após estudos e comparações a conclusão do trabalho de Dias (2006) é que as RBF mostram-se um ferramental com grande robustez e consistência para ser utilizada na previsão de demanda geradas por séries temporais.

O artigo de Gonzalez *et al.* (2006) apresenta um algoritmo evolutivo multiobjetivo para otimizar as RBF a fim de aproximar funções de um conjunto de pares de entrada e saída. O procedimento permite a aplicação de heurísticas para melhorar a solução do problema em questão, incluindo alguns novos operadores genéticos no processo evolutivo. Estes novos operadores são baseadas em duas conhecidas transformações de matriz: decomposição em valores singulares (SVD) e o método de mínimos quadrados ordinários (MQO), que têm sido utilizados para definir novas operações de mutação que produzem modificações locais ou globais nas funções de base radial das Redes Neurais (os indivíduos da população no processo evolutivo). Depois de analisar a eficiência dos diferentes operadores, Gonzalez *et al.* (2006) mostra que operadores de mutação globais tem um rendimento melhor no procedimento para ajustar os parâmetros da RBF.

Du *et al.* (2006) propõe uma estrutura probabilística para a RBF e compara seu desempenho com RBF cujos os parâmetros são definidos pelo métodos de mínimos quadrados e pelo algoritmo meta-heurístico baseado em nuvens de

partículas. O artigo é aplicado em identificação de 50 espécies de plantas e a junção dos 3 métodos para definir os parâmetros da RBF se mostrou eficiente. Também em 2006, Uysal publica um artigo discutindo a importância da definição dos parâmetros da RBF para uma série temporal de 324 dados e verifica através de testes computacionais quais são os melhores parâmetros.

A previsão de dióxido de nitrogênio da República da Macedônia foi o tema do resumo expandido publicado por Mileva-Boskoska (2007). Este texto apresenta sucintamente a comparação da RBF com o algoritmo *Support Vector Machine* (SVM) mostrando que o SVR resulta em resultados ligeiramente melhores e que um híbrido entre as duas metodologias resultou resultados melhores ainda que cada metodologia separadamente. Khairnar et al. (2007) utiliza as RBF para previsão de detecção de pulsos de radar. Os centróides são definidos empiricamente de acordo com a característica física do radar estudado.

Du e Zhang (2007) modelaram um algoritmo genético para definir automaticamente os centróides e o tamanho dos campos receptivos de cada centro. A comparação com outros trabalhos publicados com a mesma série temporal de Box & Jenkins foi realizada e os autores tiveram melhoras significativas dentre os trabalhos comparados. Em 2008, Chen et al. utiliza a RBF para séries temporais com valores complexos, aplicando-a a problemas de classificação e previsão, obtendo resultados satisfatórios. Guerra e Coelho (2008) propuseram a determinação dos centróides e campos receptivos um algoritmo baseado em nuvens de partículas e compararam com os agrupamentos realizados pelas k-médias e c-médias. Os resultados mostram uma avanço de *performance* para o algoritmo proposto.

A previsão do preço da energia elétrica volta a ser tema em um trabalho publicado por Meng et al. (2009). A novidade deste trabalho é a união da lógica fuzzy com o algoritmo de c-médias para definição dos centróides. Em 2009, Kuo et al. (2009) utilizam a RBF para previsão de vendas de uma bebida a base de mamão e leite. Para tal, os autores desenvolvem um algoritmo híbrido utilizando o PSO e o AG para definir os parâmetros da RBF. Os resultados mostram previsões muito próximas da venda real satisfazendo os objetivos iniciais do trabalho. O artigo de Lee et al. (2009) visa estudar e criar uma métrica para estimar o ruído branco de uma série temporal e como esse ruído influencia na aplicação da RBF para previsão. Os autores utilizam o parâmetro M de Welsch para eliminar esse ruído. Os

resultados mostram que uma vez identificado o ruído, até 30% dele pode ser adicionado que ainda se terá bons resultados.

O valor do preço futuro da energia elétrica volta a ser tema no artigo de Lin *et al.* (2010). Neste trabalho os autores utilizam as informações dos efeitos reais das séries e fazem uma média ponderada com esses fatores para tentar explicar a relação entrada-saída de um padrão. Os autores utilizam a quantidade de centróides igual ao número de padrões de entrada. Com este mesmo tema, Ghods e Kalantar (2010) publicam um artigo aplicando a RBF para a previsão de picos de energia no Irã. A quantidade de centróides é definida empiricamente e estes são definidos pela média de cada fator de influência da série temporal gerada. Por fim, o trabalho de Coelho e Santos (2011), que também trata do assunto de previsão do preço de energia elétrica, é desenvolvido de forma que os centróides da RBF são definidos pela média condicional (*c*-médias). A quantidade de centróides e os parâmetros são encontrados através de um algoritmo genético que maximiza a função de verossimilhança dos dados e os resultados chegaram a precisão de 80% quando os preços demonstraram queda.